

Komparativní studie segmentačních algoritmů pro identifikaci a extrakci příznaků cévního řečiště z variabilních medicínských akvizičních systémů

A Comparative Study of Segmentation Algorithms for Identification and Features
Extraction of Blood Vessels from Variable Medical Acquisition Image Systems

Bc. Jiří Herget

Diplomová práce

Vedoucí práce: Ing. Jan Kubíček, Ph.D.

Ostrava, 2021

Abstrakt

Tato práce se zaměřuje na vytvoření simulačního grafického uživatelského prostředí, ve kterém je možné porovnat metody segmentace a vliv šumu na kvalitu obrazové segmentace. Zobrazení aplikace šumu a segmentací s následnou extrakcí oblastí cévy a patologie. Nedílnou součástí je také výpočet evaluačních parametrů, jakožto objektivních ukazatelů kvality segmentace. Tyto ukazatele lze poté vynést do grafů. Grafické uživatelské prostředí je zpracováno v programu MATLAB. Zpracování výsledků je provedeno numericky a graficky. Šumy zvolené k degradaci obrazových dat byly Gaussův šum, šum Salt & Pepper, šum Speckle a Rician šum. Využitými segmentačními metodami byly metoda víceúrovňového prahování Otsu a metoda Fuzzy C-means. Jakožto evaluační parametry byly vybrány SSIM (index strukturální podobnosti), MSE (střední kvadratická chyba), korelační koeficient, Dice koeficient, rozdíl plochy extrahovaných regionů, kalcifikační skóre a jeho rozdíl. Výstupem je složka reportu obsahující grafické výstupy dávkové aplikace šumu, dávkové segmentace, grafů evaluačních kritérií a strukturálního souboru vypočtených hodnot.

Klíčová slova

Cévy, Kalcifikace, Obrazová segmentace, Evaluace, CT, MRI, Šum, Otsu, FCM

Abstract

This thesis is focused on creating a simulation graphical user interface in which is possible to compare segmentation methods and an influence of noise on the quality of image segmentation. Display of noise application and segmentation with subsequent extraction of blood vessels and pathology. An integral part is also the calculation of evaluation parameters as objective indicators of segmentation quality. These indicators can then be plotted. The graphical user interface is created in MATLAB. The results are processed numerically and graphically. Noises selected for image data degradation were Gaussian noise, Salt & Pepper noise, Speckle Noise and Rician noise. Used segmentation methods were the Otsu multilevel thresholding and the Fuzzy C-means method. As evaluation parameters were chosen SSIM (structural similarity index), MSE (mean square error), correlation coefficient, Dice coefficient, difference of area of extracted regions, calcification score and its difference. The output is a report file containing graphical outputs of the batch noise application, batch segmentation, graphs of evaluation criteria and a structural variable of calculated values.

Keywords

Blood vessels, Calcifications, Image segmentation, Evaluation, CT, MRI, Noise, Otsu, FCM

Poděkování

Rád bych poděkoval vedoucímu diplomové práce Ing. Janu Kubičkovi, Ph.D. za odborné vedení, vstřícnost a trpělivost při konzultacích, ochotu a odbornou pomoc při zpracování této diplomové práce. Dále bych rád poděkoval rodině za podporu a trpělivost.

Obsah

Seznam použitých symbolů a zkratk	7
Seznam obrázků	8
Seznam tabulek	10
1 Úvod	11
2 Cévní systém	13
2.1 Srdečně cévní systém a jeho segmenty	13
2.2 Funkční typologie cév	15
2.3 Lymfatický systém	16
3 Cévní onemocnění, jejich rozdělení, základní patologie a diagnostika	17
3.1 Ateroskleróza	17
3.2 Základní cévní onemocnění, jejich diagnostika a terapie	21
3.3 Instrumentální diagnostické metody k detekci cévních onemocnění	28
3.4 Zobrazení kalcifikací při diagnostických metodách	31
4 Zpracování obrazu cévního systému	33
4.1 Konvoluce	34
4.2 Lineární filtrace	34
5 Úvod do segmentace obrazu	35
5.1 Definice segmentace	36
5.2 Metody segmentace obrazu	36
5.3 Prahování	37
5.4 Detekce hrany	39
5.5 Metody hledání oblastí	41
5.6 Hybridní metody	43
5.7 Metody deformovatelných modelů	45

5.8	Metoda shlukové analýzy	46
6	Úvod do realizace práce	51
6.1	Vstupní datasety	51
7	Šumové generátory a jejich aplikace	53
7.1	Gaussův šum	53
7.2	Salt and Pepper šum	55
7.3	Speckle šum	56
7.4	Ricianův šum	58
8	Použité segmentační metody	60
8.1	Metoda Otsu	60
8.2	Metoda Fuzzy C-means	61
9	Vyhodnocení kvality segmentace	62
9.1	Index strukturální podobnosti (SSIM)	62
9.2	Dice koeficient	63
9.3	Střední kvadratická chyba (MSE)	63
9.4	Kalcifikační skóre	63
9.5	Korelační koeficient	64
9.6	Rozdíl kalcifikačního skóre	64
9.7	Rozdíl ploch segmentací	65
10	Zpracování grafického uživatelského rozhraní	66
10.1	Grafické uživatelské prostředí (GUI) – uživatelská část	66
10.2	Grafické uživatelské prostředí (GUI) – algoritmická část	70
11	Výstupy a výsledky z GUI	74
11.1	První skupina – obrazová	74
11.2	Druhá skupina – obrazová	82
11.3	Třetí skupina – datová	89
11.4	Automaticky generovaný strom složek reportu	90
11.5	Kroky práce s GUI	92
12	Závěr	94
	Literatura	96
	Přílohy	98

Seznam použitých zkratk a symbolů

AAA	– Abdominal Aortic Aneurysm; Výduť břišní aorty
ABI	– Ankle Brachial Index; Index kotníkových tlaků
CMP	– Cévní Mozková Příhoda
CT	– Computed Tomography; Výpočetní tomografie
GUI	– Graphical User Interface; Grafické uživatelské prostředí
HDL	– High Density Lipoproteins
HU	– Hounsfieldova jednotka
ICHDK	– Ischemická Choroba Dolních Končetin
ICHS	– Ischemická Choroba Srdeční
IVUS	– Intravascular Ultrasound; Intravaskulární ultrazvuk
LDL	– Low Density Lipoproteins
MRI	– Magnetic Resonance Imaging; Magnetická rezonance
MSE	– Mean Square Error; Střední kvadratická chyba
NAP	– Nestabilní Angina Pectoris
PDF	– Probability Density Function; Hustota rozdělení pravděpodobnosti
PWV	– Pulse Wave Velocity; Rychlost šíření pulzové vlny
ROI	– Region Of Interest; Oblast zájmu
RTG	– Rentgen
SNR	– Signal to Noise Ratio; Odstup signálu od šumu
SSIM	– Structural Similiarity Index; Index strukturální podobnosti
SWI	– Susceptibility Weighted Imaging; Susceptibilitně váhované zobrazování
switch	– Stavový přepínač
workspace	– Prostor pro zpracovávání proměnných

Seznam obrázků

3.1	Snímek stenózy	18
3.2	Snímek aneurysma	24
3.3	Snímek stentu	32
5.1	Příklad histogramu	35
5.2	Binární segmentace	38
5.3	Princip region growing	42
5.4	Princip split and merge	43
5.5	Wavelet algoritmus	44
5.6	Příklad level-set	46
5.7	Příklad shlukování	47
5.8	Princip Euklidovy metriky	48
6.1	Testovací snímky datasetů.	52
7.1	Aplikace Gaussova šumu – CT	54
7.2	Aplikace Gaussova šumu – MRI	54
7.3	PDF Gaussova šumu	55
7.4	Aplikace šumu Salt and Pepper – CT	56
7.5	Aplikace šumu Salt and Pepper – MRI	56
7.6	Aplikace šumu Speckle – CT	57
7.7	Aplikace šumu Speckle – MRI	57
7.8	Aplikace Riciánova šumu – CT	58
7.9	Aplikace Riciánova šumu – MRI	59
7.10	Ricianova distribuce	59
8.1	Ukázka segmentace pomocí metody Otsu	60
8.2	Ukázka segmentace pomocí metody Fuzzy C-means	61
10.1	Vývojový diagram pro práci uživatele s GUI.	67

10.2	Záložka dávkové aplikace šumu s označenými komponentami.	68
10.3	Záložka dávkové segmentace s označenými komponentami.	69
10.4	Záložka evaluace segmentace s označenými komponentami.	69
10.5	Způsob práce vytvořeného GUI.	70
10.6	Algoritmus dávkové degradace snímků šumem.	71
10.7	Algoritmus dávkové segmentace.	72
10.8	Volba zobrazení evaluačních parametrů.	73
11.1	Výstup z dávkové aplikace šumu – CT.	75
11.2	Výstup z dávkové segmentace pomocí Otsu metody – CT.	75
11.3	Výstup z dávkové extrakce regionů cévy – Otsu – CT.	76
11.4	Výstup z dávkové extrakce regionů kalcifikace – Otsu – CT.	76
11.5	Výstup z dávkové segmentace pomocí Fuzzy C-means metody – CT.	77
11.6	Výstup z dávkové extrakce regionů cévy – Fuzzy C-means – CT.	77
11.7	Výstup z dávkové extrakce regionů kalcifikace – Fuzzy C-means – CT.	78
11.8	Výstup z dávkové aplikace šumu – MRI.	79
11.9	Výstup z dávkové segmentace pomocí Otsu metody – MRI.	79
11.10	Výstup z dávkové extrakce regionů cévy – Otsu – MRI.	80
11.11	Výstup z dávkové segmentace pomocí Fuzzy C-means metody – MRI.	80
11.12	Výstup z dávkové extrakce regionů cévy – Fuzzy C-means – MRI.	81
11.13	Snímek grafu trendu vývoje SSIM v závislosti na šumu – CT.	83
11.14	Snímek grafu trendu vývoje MSE v závislosti na šumu – CT.	83
11.15	Snímek grafu trendu vývoje Dice v závislosti na šumu – CT.	84
11.16	Snímek grafu trendu vývoje Corr v závislosti na šumu – CT.	84
11.17	Snímek grafu trendu vývoje KS v závislosti na šumu – CT.	85
11.18	Snímek grafu trendu vývoje rozdílů KS v závislosti na šumu – CT.	85
11.19	Snímek grafu trendu vývoje rozdílů plochy v závislosti na šumu – CT.	86
11.20	Snímek grafu trendu vývoje SSIM v závislosti na šumu – MRI.	86
11.21	Snímek grafu trendu vývoje MSE v závislosti na šumu – MRI.	87
11.22	Snímek grafu trendu vývoje Dice v závislosti na šumu – MRI.	87
11.23	Snímek grafu trendu vývoje Corr v závislosti na šumu – MRI.	88
11.24	Snímek grafu trendu vývoje rozdílů plochy v závislosti na šumu – MRI.	88
11.25	Načtený soubor <i>Report.mat</i> ve workspace.	90
11.26	Hierarchie stromu složky reportu.	91
11.27	Zobrazení postupných kroků práce v GUI.	93

Seznam tabulek

6.1	Specifikace datasetu z CT a MRI.	51
11.1	Přehledová tabulka obsahu složky <i>Figs.</i>	74
11.2	Přehledová tabulka obsahu složky <i>Eval.</i>	82
11.3	Obsah výstupní datové proměnné	89

Kapitola 1

Úvod

Cévní onemocnění, jinak také kardiovaskulární a žilní onemocnění, jsou v populaci hlavní příčinou úmrtnosti. Mezi další rizikové faktory cévních onemocnění patří především životní styl, jako je sedavé zaměstnání, nadváha, kouření a s nimi spojená vysoká hladina LDL cholesterolu a nelze opomenout také dědičnost.

Tato práce se zaměřuje na kalcifikace nacházející se v cévním řečišti. Kalcifikace jsou nejlépe zobrazitelné při CT, MRI, ultrazvukovém a rentgenovém vyšetření, a z invazivních metod při angiografii. Kalcifikace jsou na rentgenových snímcích dobře viditelné v případě, že jsou rozsáhlé, často lze pozorovat zvláště na nativním snímku břicha kalcifikace v abdominální aortě a větvení ilických tepen.

Hlavní náplní této práce je segmentace medicínských snímků cév se zaměřením na kalcifikace. Cílem je návrh a implementace vybraných segmentačních metod a následná komparativní analýza. Ze snímků, jež prošly regionální segmentací lze extrahovat regiony zájmu, z nichž můžeme poté získávat statistické údaje.

Kapitola 2 se zabývá cévním systémem z anatomického hlediska. Postupně jsou probrány všechny úrovně oběhového systému. S anatomickými vědomostmi je pak možné navázat kapitolou 3, jež rozebírá fyziologii a patologii cévního řečiště. Z patologického hlediska jsou probírána onemocnění oběhového systému, a to konkrétně cévní onemocnění, mezi které například patří ischemické choroby, disekce, či vaskulitidy.

Kapitola 4 se zaměřuje na kroky, jež předcházejí samotné segmentaci. Těmito kroky jsou snímání, digitalizace a následné filtrování. Kapitola 5 je věnována definování segmentace jako takové a jednotlivým segmentačním metodám. Segmentační metody se dělí na prahování, hranové detektory, hledání oblastí, hybridní metody, aktivní kontury a metody shlukové analýzy.

Následně je nutné seznámení se s šumovými generátory, jež budou užity k degradaci snímků. Tyto generátory jsou popsány v kapitole 7. Poté následuje kapitola 8, jež se zabývá použitými segmentačními metodami. Evaluace kvality segmentace je zajištěna pomocí parametrů, jež jsou blíže popsány v kapitole 9. Mezi hlavní parametry patří například index strukturální podobnosti, střední kvadratická chyba, Dice koeficient, korelační koeficient a kalcifikační skóre.

Vybrané generátory šumu, segmentační metody a evaluační parametry jsou zapracovány do grafického uživatelského prostředí tak, aby poskytly možnost jednoduché simulace degradace dat a následné segmentace s možným kvalitativním vyhodnocením dle dříve zmíněných metrik. Grafické uživatelské prostředí, jinak také GUI, je podrobně popsáno v kapitole 10, na kterou poté navazuje kapitola 11, jež se zabývá výstupy simulace, jež jsou jak grafické, tak numerické.

Kapitola 2

Cévní systém

Cévní systém u člověka zajišťuje transport krve a tím i výměnu životně důležitých látek a krevních plynů mezi tkáněmi. Cirkulace krve jakožto transportního media je nepřetržitá, zajišťována funkcí srdce a cév na úrovni dvou sériově řazených oběhů (systémového, kdy vypuzování krve zajišťuje levá komora srdeční a plicního oběhu, kde tuto funkci plní pravá komora srdeční). Právě správná funkce srdečního svalu a cévního řečiště je klíčová pro správnou látkovou výměnu a funkci orgánových soustav člověka. Jakýkoliv patologický stav v této lokalizaci má významný dopad na další tělní tkáně, orgány, a proto je z medicínského hlediska zásadní správná, účelná a přesná diagnostika tohoto systému. [1, 2]

2.1 Srdečně cévní systém a jeho segmenty

Pokud jde o dělení srdečně cévního systému, jak již z názvu vyplývá, jeho dvě nejdůležitější části jsou srdce a cévy. Cévy dále dělíme dle směru proudění krve, a to na tepny, které vedou krev ze srdce a žíly, které ji vedou k srdci. Dále sem patří arterioly a kapiláry neboli vlásečnice. [1, 2]

2.1.1 Srdce

Srdce je dutý svalový orgán, který pod tlakem pohání krev v oběhu tím, že se rytmicky smršťuje a ochabuje, systola je stah srdce, diastola je ochabnutí, uvolnění stahu. Uvnitř srdce usměrňují tok krve srdeční chlopně, konkrétně v systole pomáhají vypuzování krve do tepen a v diastole je následně krev ze žil nasávána do srdce a zároveň je i zamezeno zpětnému toku krve. Pro účely této práce je důležité zejména rozdělení srdce na levou a pravou srdeční komoru srdeční a jejich základní funkce. Levá srdeční komora vypuzuje krev tepnami systémového oběhu ke krevním kapilárám na periferii těla. Žilami se krev dostává zpět do srdce a je pak pravou srdeční komorou vypuzována do malého (plicního oběhu) a jím je opět přiváděna do levého srdce [1, 2].

2.1.2 Tepny (arterie)

Tepny mají pevné a pružné stěny, adaptované na pulsové nárazy krve rytmicky vypuzované ze srdce. Krev protéká v tepnách nejrychleji za systoly, například v aortě činí rychlost proudění krve asi 40–50 m/s, s větvením řečiště pak rychlost ubývá. Aorta a velké tepny následně odvádějí krev do periferie a mají takzvanou pružnickovou funkci. Jejich stěna se ve vypuzovací fázi roztáhne vlivem působení systolického tlaku, následně se tepny vrací zpět do původního stavu ihned po uzavření aortální chlopně a poklesu tlaku v řečišti, tím rovněž udržují proudění krve i během diastoly. [2]

Běžný tlak krve za systoly činí v aortě 140–150 mmHg, v arteria brachialis kolem 120 mmHg a v arteria radialis přibližně 90 mmHg, směrem k periférii tlak krve klesá. Příčinou zpomalení proudu krevního toku i krevního tlaku do periferie je skutečnost, že s postupným přibýváním větví obnáší součet ploch průřezů větví vždy více, než plocha průřezu cévy před větvením [1].

Tepenné větve, které vedou podle hlavního kmene a napojují se v jeho směru na další tepny se označují jako kolaterály, těmito větvemi poté v případě uzávěru hlavní tepny dále probíhá krevní zásoba daného orgánu či tkáně. Toto má hlavní význam při některých cévních onemocněních, jakým je například ischemická choroba dolních končetin. [1]

Stěna tepen se skládá ze tří základních vrstev, vnitřní vrstvu nazýváme tunica intima, střední tunica media a vnější tunica externa neboli adventicie.

1. Tunica Intima: Skládá se z jedné vrstvy plochých endotelových buněk podložených sítí elastických a kolagenních vláken nebo elastickými blankami. [1, 3]
2. Tunica Media: Nejsilnější z vrstev tepny, skládá se z hladké svaloviny, jejíž buňky probíhají cirkulárně nebo v nízkých spirálovitých závitěch, mezi nimiž jsou sítě kolagenních a elastických vláken. Podle velikosti tepen převažuje buď elastická nebo svalová složka a cévy poté označujeme jako elastického či svalového typu. Velké tepny, mezi které patří například aorta, karotické tepny, jsou elastického typu, tepny středního průřezu mají obě složky v relativní rovnováze a tepny malého průřezu jsou již pouze svalového typu. [1, 3]
3. Tunica Externa: Je tvořena adventicií a zevní elastickou membránou, která odděluje adventicii od tunica media. Adventicie je tvořena elastickými vlákny, která jsou důležité pro mechanické zakotvení cévy. Také adventicií procházejí cévy, tzv. vasa vasorum, které zásobují jak adventicii a zevní vrstvu tunica media, dále tudíž prochází také autonomní nervová vlákna, která inervují svalovinu medie. [1, 3]

2.1.3 Arterioly

Nejtenčí arterie, skládají se z endotelové vrstvy a tenké vrstvy cirkulárně uložených svalových buněk, mezi nimi probíhá tzv. membrána elastica interna. Arterioly mají poměrně silnou stěnu, ale malý průsvit, jsou bohatě inervovány autonomními nervovými vlákny, regulují průtok krve rychlou změnou průsvitu. Před kapilárami se mění v prekapiláry. [1]

2.1.4 Kapiláry

Velmi úzké cévy, stěnu tvoří pouze vrstva endotelových buněk. Změna průsvitu probíhá pasivně, nejběžněji průsvit odpovídá rozměru červených krvinek. Dále se průsvit mění také působením hormonů a jiných působků, např. adrenalinu, histaminu či CO₂. Pokračují dále jako postkapiláry, které ve stěně mají i několik buněk hladké svaloviny. [1]

2.1.5 Žíly (vény)

Žíly velkého oběhu sbírají krev z orgánů a tkání. Postupně se spojují a jako v. cava superior a v. cava inferior se posléze vlévají do pravé síně.

Žilní stěna je tenčí než stěna arterií, tunica intima obsahuje většinou pouze jednu vrstvu svalových buněk a tunica elastica intima není většinou souvislá. Žíly obsahují tzv. žilní chlopně, jsou to endotelem kryté výběžky intimy, uvnitř vyztužené potřebným množstvím vaziva [1]. Mají poloměsíčitý tvar, nad chlopněmi se při krevní náplni stěna vyklenuje, za patologických stavů se nad chlopněmi tvoří uzlovitá rozšíření, tzv. žilní městky, varixy. Chlopně pomáhají toku krve a také regulaci hydrostatického tlaku. [1]

Jako součást nízkotlakého systému mají díky své kapacitě důležitou úlohu jako krevní rezervoár, centrální žilní tlak, měřený v zaklínění v pravé síni, je závislý na objemu krve a obvykle se pohybuje mezi 0–12 cm H₂O, je využíván převážně ke sledování objemu krve. Krevní tlak v žilním systému se pohybuje při fyziologických stavech mezi 5–20 mmHg. Tlak v žilách klesá směrem k srdci [1].

2.2 Funkční typologie cév

Představuje dělení cévního systému z funkčního hlediska, kategorií zde rozlišujeme šest.

1. Pružníkový systém: Jak již vylo zmíněno výše, velké a středně velké tepny, které jsou elastického typu, tedy u nich převažuje svalová vrstva v tunica media, zajišťují rychlý transport krve do periferie. Jejich výrazné elastické vlastnosti mají navíc význam v přeměně nárazového přítoku krve v systole na její kontinuální proudění. Tento efekt se pochopitelně projevuje hlavně v aortě [3]

2. Rezistenční cévy: Tyto cévy regulují přítok krve k orgánům a tkáním, jde hlavně o:
- (a) Malé tepny a tepénky, tzv. prekapilární rezistenční cévy. Mají malý průsvit, rovněž je ve stěně přítomen vysoký podíl hladkých svalových vláken, která právě umožňují velké změny v průsvitu cévy a tím následně regulují tok krve k cílové tkáni. Dochází tak k distribuci minutového objemu krve dle aktuálních požadavků daného orgánu.
 - (b) Venuly, tzv. postkapilární rezistenční cévy, které vytvářejí jen velmi malou část rezistence. Jejich hlavní funkce spočívá v tom, že rozdílem mezi tonem prekapilárních a postkapilárních rezistenčních cév je určován kapilární hydrostatický tlak, který umožňuje látkovou výměnu – tzv. filtraci a resorpci. [3]
3. Prekapilární sfinktery: Konečné úseky prekapilárních tepének, jejich konstrikce a vazodilatace rozhoduje o počtu otevřených kapilár a tím i o velikosti kapilární plochy. [3]
4. Kapiláry: Styčná plocha mezi krví a tkáněmi, zde probíhá látková výměna, výměna krevních plynů. Kapiláry mají tenkou cévní stěnu, bez možnosti kontrakce a jsou schopny se deformovat podle procházejících krevních elementů, změna průsvitu je tedy pasivní. [3]
5. Arteriovenózní zkratky: Jsou přítomny pouze v některých tkáních, zabezpečují rychlý převod krve z tepenného do žilního řečiště, krev tedy neprochází kapilárami, díky tomu se zrychluje průtok krve tkáněmi. [3]
6. Kapacitní cévy: Především žíly, díky své roztažnosti pojímají značný objem krve, který poté funguje jako rezervoár, poté je využíván při měnící se distribuci krve. Tunica media je daleko slabší v žilní stěně, tvoří ji jen tenká vrstva svalových buněk. [3]

2.3 Lymfatický systém

Pouze krátkou zmínkou je třeba do kompletního systému uvést lymfatický systém, který je zcela samostatný, začíná vlasečnicemi a poté se sbíhá do hlavních kmenů, poté ústí do velkých žil. Odvádí tkáňový mok s vysokomolekulárními látkami, pro které je kapilární stěna nepropustná, nebo jen málo propustná. [1]

Tyto poznatky jsou zásadní pro porozumění cévnímu systému v lidském těle, jde o základy, o které se následně opírá diagnostika veškerých patologických stavů. [3]

Kapitola 3

Cévní onemocnění, jejich rozdělení, základní patologie a diagnostika

Cévní onemocnění, jinak také kardiovaskulární a žilní onemocnění, jsou v populaci hlavní příčinou úmrtnosti. Můžeme je rozdělit na onemocnění tepenného systému, žilního systému a choroby postihující převážně kapiláry a venuly.

Řada cévních onemocnění se rozvíjí na podkladě aterosklerotických změn a na ně nasedajících dalších změn v cévní stěně a poruše přilnavosti krevních elementů. Poté zde můžeme zařadit onemocnění na podkladě trombembolismus vznikající především při změnách reologických vlastností krve (například při dehydrataci, působením hormonálních změn či při genetických mutací genů pro srážlivost) či mechanických poruchách (např. imobilizace končetin, nefunkčnost žilních chlopní).

Mezi další rizikové faktory cévních onemocnění patří především životní styl, jako je sedavé zaměstnání, nadváha, kouření a s nimi spojená vysoká hladina LDL cholesterolu. Nelze opomenout také dědičnost.

3.1 Ateroskleróza

Ateroskleróza je chronické zánětlivé onemocnění cévní stěny, především její intimy, jejíž struktura je alterována tvorbou ateromů. Po řadě let či desetiletí asymptomatického průběhu se onemocnění manifestuje svými komplikacemi: ischemickou chorobou srdeční (ICHS), ischemickou cévní mozkovou příhodou (CMP) nebo ischemickou chorobou dolních končetin (ICHDK), méně často pak komplikacemi v jiných lokalizacích (obliterace karotid, abdominální angina a další). [4]



Obrázek 3.1: MRI snímek oblasti horní části thoraxu a hlavy s patologickým nálezem stenózy (zúžení) na arteria carotis interna sinistra. Zdroj vlastní.

3.1.1 Ateroskleróza a její patogeneze, rizikové faktory

Je důležité uvědomit si, že příčina vzniku aterosklerózy je multifaktoriální, vzniká jako reakce na poškození cévní stěny. Přesný faktor vzniku není zcela znám, rozlišujeme však řadu rizikových faktorů, mezi ně patří, jak už bylo zmíněno výše, především zvýšená hladina LDL cholesterolu, který tvoří základ aterosklerotického ložiska. [4]

3.1.2 Vznik aterosklerotických změn

Teorie vzniku aterosklerotických změn, která je považována za nejvíce odpovídající je ta, která pracuje s předpokladem, že prvním a spouštěcím faktorem je vznik endoteliální dysfunkce při poškození endotelu. Jedná se většinou o poškození, které je lokalizováno na konkrétním místě, není postižena integrita, ale již jde o alteraci funkcí, kdy endoteliální buňky zvyšují propustnost pro některé molekuly. Takto následně vzniká nerovnováha mezi vazodilatačními a vazokonstrikčními mechanismy, tedy mezi vazodilatací a vazokonstrikcí a hemokoagulačními působky, mezi které řadíme prokoagulační a protrombotické a naopak antitrombotické faktory). Dochází tak k převaze protrombotických a vazokonstrikčních pochodů a tím k aktivaci zánětlivé odpovědi a proliferace. [4]

Také dojde ke zvýšené adhezii trombocytů k poškozenému místu a tím nárůstu trombotické hmoty, dochází k ukládání lipoproteinů, tedy LDL, do místa migrují další buňky, jako například monocyty mění se na makrofágy. Do místa se také atrahují svalové buňky, dochází postupně ke vzniku fibrinových vláken a izolaci trombolipidového jádra od cirkulující krve. Vzniká tak tzv. tromb-ateromová léze, pokud dojde k fisuře či ruptuře plátu, nasedá zde trombóza a kriticky se mění průsvit arterie, či dochází k jejímu úplnému uzavření. [4]

3.1.3 Rizikové faktory

Rizikové faktory navozují změny v endotelu, lze je dále rozřadit na faktory modifikovatelné a nemodifikovatelné podle možnosti jejich ovlivnění. Dále na faktory dle jejich významu a příčinnosti, tedy na hlavní a vedlejší.

3.1.3.1 Hlavní rizikové faktory aterosklerózy

Tyto faktory jsou nezpochybnitelné a zcela jistě se podílejí na vzniku aterosklerotických změn v organismu.

Mezi modifikovatelné patří hypercholesterolémie – tedy zvýšený LDL cholesterol. Při snížení jeho koncentrace o 1 % vede k poklesu rizika koronárních příhod o 1–2 %. Podle aktuálních dat je požadovaná hladina LDL cholesterolu v prevenci aterosklerózy pod 1,2 mmol/l, u osob s prokázanými komplikacemi na podkladě aterosklerotických změn nově usilujeme o hladinu pod 0,8 mmol/l. Dále

zde radíme arteriální hypertenzi, která způsobuje zejména mechanické poškození endotelu, provokuje totiž v endotelu oxidativní stres, kdy vzniká superoxidový radikál, který inaktivuje NO, dojde tedy k převaze vazokonstrikčního účinku endotelinu. Endotelin dále poškozuje i zvýšená hladina angiotensinu II, který se nejen podílí na vazokonstrikci, ale také zvyšuje propustnost endotelu. Za optimální tlak považujeme hodnotu kolem 120/80 mmHg, u mužů středního věku, u kterých se systolický tlak pohybuje nad 160 mmHg je riziko rozvoje aterosklerotických komplikací 5krát vyšší, než u normotenzních osob. [4]

Kouření je jeden z nejrozšířenějších modifikovatelných rizikových faktorů, zde se jedná o přímý toxický vliv zplodin na cévní stěnu, u kuřáků rovněž díky tomuto působení převažuje vazokonstrikční složka a významně se potlačuje vazodilatace. Zvýšení oxidativního stresu rovněž zvyšuje oxidaci LDL. Celkově kouření podporuje rozvoj dyslipidémie, působí prokoagulačně vzhledem k tomu, že zvyšuje viskozitu krve při polycytémii, kterou se tělo snaží kompenzovat relativní hypoxií (je snížena vazebná kapacita pro kyslík působením CO). [4]

Mezi dalšími můžeme jmenovat především diabetes mellitus a rovněž inzulinovou resistenci, kdy je zvýšena oxidativní modifikace LDL a dochází opět ke snadnějšímu ukládání do cévní stěny, je narušena vazodilatace a dochází k rozvoji makro a mikroangiopatie, také fyzická inaktivita a obezita centrálního typu (na podkladě hromadění abdominálního tuku) patří mez modifikovatelné faktory vzniku aterosklerózy. [4]

Mezi nemodifikovatelné faktory řadíme věk nad 45 let u mužů a nad 55 let u žen, mužské pohlaví (u žen se uplatňuje protektivní působení estrogenů až do menopauzy) a pozitivní rodinná anamnéza ischemických chorob v časném věku. [4]

3.1.3.2 Vedlejší rizikové faktory

Mezi vedlejší rizikové faktory patří snížená hladina HDL cholesterolu, který působí protektivně proti vzniku endoteliální dysfunkce, hypertriglyceridemie, zvýšená hladina C reaktivního proteinu (jako důsledek zánětlivých procesů), zvýšená hladina lipoproteinu a či elevace hladin homocysteinu. [4]

3.1.4 Stupně vývoje aterosklerózy:

Proto, abychom mohli důsledně pracovat s diagnostickými metodami a řádně je hodnotit, je důležité znát patologii vývoje aterosklerotického plátu, teprve poté můžeme při jeho hodnocení zobrazovacími metodami správně zhodnotit aktuální nález a rizika pro pacienta, případně zvážit, jaký princip zobrazení je v daném případě nejvhodnější. [4]

- Typ I.: Foam cells, tzv. pěnové buňky: V tunica intima se objevují skupiny makrofágů, které obsahují ve své cytoplazmě kapénky lipidů. Objevují se již v dětském věku a lze je dete-

kovat pouze mikroskopicky v preparátu. Toto stadium tedy nelze diagnostikovat klasickými zobrazovacími metodami.

- Typ II. : Fatty stripes, tzv. tukové proužky: vznikají z pěnových buněk.
- Typ III. : Intermediální poškození: již se objevuje lipidová vrstva uložená pod proužky pěnových buněk.
- Typ IV. : Aterom neboli měkký plát: dochází k hustému nahromadění extracelulárních lipidů – tedy dojde rozpadem pěnových buněk ke vzniku lipidového jádra, dojde ke vzniku depozita cholesterolu a kalcia.
- Typ V. : Stabilní plát: již obsahuje pojivovou tkáň která se vyklenuje do lumen cévy, je zde přítomen vyšší obsah kolagenu a svalových buněk, dochází rovněž k vaskularizaci plátu.
- Typ VI. : Vulnerabilní plát: jde o lézi čtvrtého nebo pátého typu, kdy byl plát narušen a dochází k cévní okluzi nasedáním trombotických hmot. Do tohoto typu zařazujeme také aterosklerotické aneurysma, kde dochází k erozi intimy a alteraci tunica media a vyklenutí cévní stěny.

Od typu 4 a výše lze detekovat aterosklerotické pláty běžnými vyšetřovacími metodami.

3.1.5 Kalcifikace aterosklerotického plátu

Kalciová depozita jsou charakteristická pro pokročilou aterosklerotickou lézi, jak již bylo uvedeno výše, tedy pro typ IV–VI, kalcifikováno je v těle a pouze asi 10–20 % všech aterosklerotických plátů. Kvantifikace depozit kalcia v koronárních cévách pomocí ultra-rychlé výpočetní tomografie ukázala, že přítomnost kalcifikací signifikantně zvyšuje riziko koronární příhody a osoby s vysokým kalciovým skóre mají až 6krát vyšší riziko vzniku koronární příhody než osoby bez kalcifikací. [4]

3.1.6 Prevence a léčba:

Prevence spočívá v eliminaci ovlivnitelných výše jmenovaných faktorů, především v poklesu hladin LDL cholesterolu, léčba spočívá v léčbě onemocnění, které na podkladě aterosklerózy vzniká či se podílí na jejím vzniku. K regresi aterosklerózy je nutné snížení hladiny LDL cholesterolu, je však téměř nemožné, aby došlo k plné regresi změn, zvláště pak v pozdějších stádiích. Cílená terapie k léčbě aterosklerotických změn t.č. není k dispozici. [4]

3.2 Základní cévní onemocnění, jejich diagnostika a terapie

Následující sekce se zaměřují na ischemickou chorobu srdeční, ischemickou cévní příhodu, onemocnění aorty a velkých tepen, onemocnění periferních tepen, a také chorob žil a mízního systému.

3.2.1 Ischemická choroba srdeční

Ischemická choroba srdeční je spektrum chorob, jejichž společným jmenovatelem je poškození věnčitých tepen (v naprosté většině koronární aterosklerózou) a v důsledku toho reverzibilní nebo ireverzibilní ischemie části myokardu. [5]

Mezi její akutní formy patří infarkt myokardu, nestabilní angina pectoris a náhlá srdeční smrt. Do forem chronické ICHS řadíme stav po infarktu myokardu (IM) po více než 6 týdnech, stabilní angina pectoris, nemá ischemie, vasospastická angina pectoris a chronické srdeční selhání v důsledku ICHS. [5]

Akutní infarkt myokardu i nestabilní angina pectoris mají stejného jmenovatele, tím je ruptura aterosklerotického plátu a na ni nasedající intraluminární trombóza. Dochází tak k progresi preexistující stenózy. Rozdíl mezi nestabilní anginou pectoris (NAP) a akutním infarktem myokardu je ten, že při NAP nedochází k nekróze myokardu. [5]

Akutní infarkt myokardu se stejně jako nestabilní angina pectoris projevuje dušností, bolestí na hrudi (stenokardie), někdy i zvracením, synkopou či atakou arytmií. Diagnostika spočívá kromě jiného především na správném vyhodnocení klinických příznaků, laboratorních ukazatelů (tzv. kardiopécifické markery – myoglobin, kreatinkináza a troponiny – I nebo T), EKG, rentgenového snímku a echokardiografického nálezu, hlavním léčebným prostředkem je kromě medikace provedení časné angioplastiky při perkutánní koronární intervenci, dále provedení v aortokoronárního bypassu v případě katetrizačně neřešitelné léze. [5]

Stejně tak pacienty s anginou pectoris je vhodné elektivně odesílat ke katetrizačnímu zákroku, pokud u nich existuje podezření na významnou stenózu (např. při významné námahové dušnosti, pozitivním nálezu při ergometrii, poruše kinetiky levé komory při echokardiografickém vyšetření). Pokud je při koronarografii zjištěna významná stenóza věnčité tepny, je provedena angioplastika, nejčastěji za použití stentu a pacientovi se významně snižuje riziko vzniku akutní koronární příhody. [5]

3.2.2 Ischemická cévní mozková příhoda

Ischemické cévní mozkové příhody jsou nejčastějším typem cévního poškození mozku. Tvoří 80–85 % všech iktů. [5]

Vznik cévní mozkové příhody je charakterizován kritickým poklesem prokrvení části nebo celého mozku, klesá perfuze pod požadovanou hodnotu k zajištění mozkových funkcí, touto hladinou ro-

zumíme průtok krve pod 20 ml/100 g mozkové tkáně. Příčiny se často kombinují, na prvním místě je však stále mikroangiopatie při aterosklerotickém postižení, které způsobují stenózu až obliteraci cévního lumen, často v kombinaci s tvorbou nástěnného trombu, či jde o embolizaci z částí cévního řečiště. Mezi méně časté příčiny můžeme zařadit např. vaskulitidy, cévní spasmusy, disekce aj. [5]

Diagnostika je převážně klinická, ze zobrazovacích metod používáme invazivní i neinvazivní metody. Z neinvazivních vyšetření za zlatý standart v dnešních dnech považujeme použití CT angiografie a perfuzního CT, v mnohých případech lze těmito vyšetření nahradit invazivní angiografické vyšetření. Dále používáme magnetickou rezonanci, kde je nejvíce přínosné multimodální MRI vyšetření, kde lze vzájemně posoudit poruchu perfuze a difuze. [5]

Méně používaným neinvazivním vyšetřením je pak ultrasonografie s dopplerovským měřením hodnotící směr, rychlost a vydatnost cévního průtoku a umožňuje např. detekci aterosklerotických plátů či okluzí v karotickém řečišti. [5]

Digitální subtrakční angiografie je naopak invazivní vyšetření, které umožňuje detailní zobrazení morfologie cévního řečiště s průkazem stenóz, okluzí či případných aneurysmat., zásadní význam má při angiochirurgických a endovaskulárních intervencích. [5]

Metodou volby v léčbě se v posledních letech stává rovněž perkutánní transluminální angioplastika v kombinaci s intravaskulární trombolýzou a použitím mechanických extraktorů, dále odpovídající medikace v neposlední řadě rehabilitace a celková interní péče o pacienta. [5]

3.2.3 Onemocnění aorty a velkých tepen

Zde řadíme především aneurymatické postižení, ale dalším zástupcem disekce aorty či jiných velkých tepen.

3.2.3.1 Aneurysma

Aneurysmatem označujeme lokalizované vakovité rozšíření tepny, v případě hrudní aorty na 4 a více centimetrů, v případě břišní aorty (AAA) na 3 a více centimetrů. Vzniká především na preexistujícím aterosklerotickém postižení v kombinaci s degenerativním procesem postihujícím stěnu tepny na podkladě enzymatických pochodů, které mění strukturu stěny. Na vzniku se podílejí kromě těchto změn také genetické faktory. Onemocnění se zcela typicky vyskytuje u kuřáků, častěji u mužů. Mezi další rizikové faktory patří nekorigovaná arteriální hypertenze, ischemická choroba srdeční, ischemická choroba dolních končetin a hyperlipidemie. [5]

- Diagnostika se opírá především o klinickou manifestaci, jakou je bolest, ischemie orgánů či končetin při embolizaci, tlakem, anamnézu a vyšetření. Zobrazovací metody volby jsou zde především ultrazvukové vyšetření, CT, magnetická rezonance a arteriografie.
- Ultrasonografické vyšetření je vhodné především pro sledování nemocných s dobře zobrazitelným aneurysmatem a zároveň s dobrou vyšetřitelností, u kterých je prováděno sledování již známého AAA. CT vyšetření je nejčastěji prováděno jako spirální CT angiografie, při které lze přesně posoudit rozsah, vztah k okolí, ohrazení, případnou přítomnost trombu a může odhalit známky blížící se ruptury – tzv. sáknutí aneurysmatu.
- Léčba je převážně chirurgická, častěji se uplatňují v posledních letech endovaskulární výkony s implantací stengraftu, miniinvazivní proces představuje pro pacienta výhodu, rychlejší hojení a dobré dlouhodobé výsledky. Nutná je také dopovídající medikace a změna životního stylu.



Obrázek 3.2: MRI snímek břišní oblasti s patologickým nálezem aneurysma (výduť) na arteria iliaca communis sinistra. Zdroj vlastní.

3.2.3.2 Disekce aorty či jiných velkých tepen

Při disekci aorty či jiných velkých tepen, kdy dochází k rozštěpení cévní stěny, v případě aorty k významnému hemodynamickému poškození a často k úmrtí nemocného. V případě disekcí na menších tepnách však také může vznikat život ohrožující krvácení, neurologický deficit či ischemické změny v navazující lokalizaci. Vzniká trhlina v intimě cévy, krev tedy proudí pod tlakem do medie, vrstvy cévní stěny se oddělí a vytvoří se falešné lumen. Dále se trhlina může propagovat ve směru i proti směru krevního toku, nejčastější příčinou je arteriální hypertenze. [5]

- Diagnostika se opírá o klinický obraz, který představuje ostrou vystřelující velmi intenzivní bolesti, deficit pulzací v periferii a výrazný stranový rozdíl krevních tlaků, ze zobrazovacích metod volíme CT angiografii, typický je obraz dvou lumen a tzv. flap vlající při každé pulzní vlně v cévě, jedno z lumen je hůře syčené kontrastní látkou. Magnetickou rezonanční angiografii vzhledem k časové náročnosti pro akutní případy nepoužíváme, přestože velmi kvalitně zobrazuje měkký flap uvnitř lumen, je tedy vhodná pro chronické disekce s hemodynamickou stabilitou a nezatěžuje pacienta radiací.
- Digitální subtrakční angiografii používáme během katetrizační léčby a sondáží pravého lumen. Metodou první volby u nestabilních pacientů dále zůstává transezofageální echokardiografie multiplanární sonda dobře zobrazuje entry a reentry, za pomoci dopplerovského mapování lze posoudit tok v obou lumen a případně posoudit trombózu falešného lumen.
- Léčba je standardně chirurgická či endovaskulární, stejně jako u aneurysmat.

3.2.4 Onemocnění periferních tepen

Tato část se zaměřuje na ischemickou chorobu dolních končetin a kritickou ischemii, diabetickou angiopatii, aneurysma periferních tepen, vazoneurózy a vaskulitidy.

3.2.4.1 Ischemická choroba dolních končetin a kritická ischemie

Ischemická choroba dolních končetin vzniká na podkladě aterosklerotických změn, dochází k postupnému poškození tkání na podkladě nedostatku kyslíku a živin potřebných k její funkci. Nejčastěji jde o stenoticko – okluzivní typ poškození. Rizikové faktory ICHD jsou totožné s rizikovými faktory aterosklerózy, nejsilněji je spojena s kouřením a přítomností diabetu. [5]

Kritická končetinová ischemie je klinický syndrom projevující se klidovou ischemií nebo ischemickými kožními lézemi typu ulcerace nebo gangrén. Pro tuto diagnózu je nutné splnit alespoň jedno z následujících kritérií. [5]

1. Přítomnost klidové ischemické bolesti, která vyžaduje analgetickou léčbu po dobu delší než dva týdny s kotníkovým systolickým tlakem pod 50 mmHg a/nebo tlakem na palci pod 30 mmHg.
2. Přítomnost ulcerací či gangrén na noze či prstech s kotníkovým systolickým tlakem pod 50 mmHg a/nebo tlakem na palci pod 30 mmHg, popřípadě s transkutánní tenzí kyslíku (TcO₂) pod 10 mmHg v postižené oblasti. [5]

Tento stav je způsoben multietážovým postižením cév při aterosklerotických změnách, poruchou mikrocirkulace nízkou tkáňovou perfuzí. V klinickém obrazu nejčastěji pozorujeme akrální bolestivost, a to jak námaňovou, tak klidovou, typické jsou klaudikační bolesti, tedy bolesti vznikající při pohybu v lokalizaci pod uzávěrem nebo kritickým zúžením tepny které postupně odeznívají při odpočinku. [5]

Dále je typická ischemická bolest vznikající v klidovém stavu v očních hodinách, která nutí pacienta svěšovat končetinu z lůžka. Projevem pokročilé končetinové ischemie je tvorba ulcerací a gangrén. [5]

Diagnostika se opírá o klinický obraz, a vyšetření s měřením periferních tlaku, transkutánní tenze kyslíku, výše uvedená kritéria a samozřejmě zobrazovací metody. Metodou první volby je ultrasonografie, kde lze hodnotit rychlost a vydatnost proudění krevního toku případnou stenózou. [5]

3.2.4.2 Diabetická angiopatie

U diabetiků v typickém případě vidíme maximum postižení v oblasti bércevého řečiště, případně postižení arteria profunda femoris. Typické jsou defekty v dolní třetině bérce, kotníku a chodidle. Cévy jsou postiženy difúzně. [5]

3.2.4.3 Aneurysmata periferních tepen

Aneurysmata periferních tepen patří mezi méně časté příčiny cévních obtíží, dlouhodobě zůstávají asymptomatická a jejich nejčastější příčinou je ateroskleróza a hypertenze, dále traumata, degenerativní onemocnění medie, infekce a angiitidy. Diagnostika je především založena na průkazu embolizace do periferie, v podkolenní lokalizaci často dochází k utlačení žíly, aneurysma se tedy manifestuje vznikem flebotrombózy. Naopak disekující aneurysma může být příčinou ischemie v periferii. [5]

3.2.4.4 Vazoneurózy

Jde o přechodnou poruchu periferního prokrvení, je-li více postiženo arteriální řečištěm dochází k přechodné ischemii – např. Raynaudův fenomén, pokud je převaha v řečišti venózním, dochází k akrální cyanóze. Příčinou jsou často vaskulitidy, onemocnění pojiva, traumata a útlakové syndromy. [5]

3.2.4.5 Vaskulitidy

Projevují se zánětlivým postižením cévní stěny vedoucím místy až k nekrózám, je především segmentální, difuzní postižení je málo obvyklé. Typické jsou léze cévní stěny neateroskleotického původu. [5]

3.2.5 Choroby žil a mízního systému

Následující pasáž se zaměřuje na hlubokou žilní trombózu, žilní nedostatečnost a varixy, a onemocnění lymfatického systému.

3.2.5.1 Hluboká žilní trombóza

Hluboká žilní trombóza vzniká nejčastěji v dolních končetinách, jako flebotrombózu označujeme primární trombózu, jako tromboflebitidu pak stav, při němž se trombóza rozvíjí při vlastním poškození žilní stěny. Její akutní komplikací bývá plicní embolie, chronickými komplikacemi pak jsou posttrombotický syndrom, opakovaný vznik hluboké žilní trombózy a plicní hypertenze. [5]

Při postižení hlubokých pánevních, stehenních a podkolenních žil mluvíme o proximální hluboké žilní trombóze, při distální hluboké žilní trombóze jsou postiženy především bérkové žilní kmeny. [5]

Na rozvoji se podílí řada rizikových faktorů, mezi kterými můžeme jmenovat například věk, protražovaná hospitalizace, větší chirurgický výkon, imobilizace, srdeční selhání, těhotenství, malignity či zánětlivá onemocnění a také genetické faktory, jako jsou četné mutace v koagulační kaskádě. [5]

Diagnostika se opírá o klinický obraz, anamnézu a laboratorní markery, ze zobrazovacích metod se nejspolehlivěji uplatňuje ultrasonografie s dopplerovským mapováním, která posuzuje průtok ve vyšetřovaném bodě a je schopna efektivně zhodnotit přítomnost trombotických hmot v lumen žíly. Dříve používaná RTG kontrastní flebografie byla nahrazena CT či MR flebografií, v klinické praxi se však příliš nevyužívá. [5]

Léčba zahrnuje antikoagulační terapii, v případě rozsáhlého nálezu lez použít trombolýzu, endovaskulární či chirurgický zákrok s trombektomií. Nezbytnou součástí terapie je kompresní léčba. [5]

3.2.5.2 Žilní nedostatečnost a varixy

Degenerativní žilní choroba, která je podmíněna fibrózou intimy žilní stěny, převážně u povrchových žil. Primárně nedochází k poškození žilních chlopní, k jejich insuficienci dojde při dilataci žíly. Varixy se často spojují s chronickým městnáním krve v žilním systému, což označujeme jako žilní nedostatečnost. Klinicky se projevuje trofickými změnami na kůži, otokem a ulceracemi. Ze zobrazovacích metod je metodou volby duplexní ultrasonografie, terapie je medikamentózní či chirurgická, t.č. převážně intervenčního charakteru. [5]

3.2.5.3 Onemocnění lymfatického systému

Z cévního hlediska do této kategorie řadíme lymfedémy, což je nahromadění lymfatické tekutiny v končetinách, obličeji, genitálu, břiše či hrudníku. [5]

3.3 Instrumentální diagnostické metody k detekci cévních onemocnění

Tato část se zabývá diagnostickými metodami, jež jsou používány k detekci cévních onemocnění. Mezi tyto metody patří Dopplerovské měření, ultrasonografické vyšetření, měření kotníkových tlaků, Kapilaroskopie, pletysmografie, CT angiografie a mnoho dalších. [6]

3.3.1 Dopplerovské vyšetření

K dopplerovskému vyšetření se používají jednoduché přístroje, které umožňují pomocí tužkových ultrazvukových sond využívajících kontinuální dopplerovský princip zobrazit rychlost a směr proudění krve. Využívají principu, kdy se mění frekvence mechanického, tedy rovněž ultrazvukového, vlnění odraženého od pohybujících se částic podle rychlosti jejich pohybu. [6]

3.3.2 Měření kotníkových tlaků

Tato metoda je rychlá a efektivní, slouží ke zhodnocení ischemie končetiny, spolu s fyzikálním vyšetřením má vysokou senzitivitu i specifitu. Touto metodou lze jednoduše určit místo a tíži poškození tepenného systému na dolních končetinách. K měření je využívána tužková sonda doppleru (8 MHz) umožňující detekci zvukového signálu tepenného toku a tonometr, jehož manžeta je umístěna na distálním bérce. [6]

Tužkovým Dopplerem je pak nutno najít tepenný signál, nejčastěji na a. tibialis anterior a a. tibialis posterior, manžeta tonometru je nafouknuta na suprasystolický tlak, kdy dochází k vymizení signálu, postupným upouštěním vzduchu je následně tlak v manžetě snižován, hodnota, při které se zvukový signál znovu objevuje je hodnota krevního tlaku na dané cévě. Získaný tlak je dán d souvislosti s arteriálním tlakem na horní končetině, je získán tzv. ABI (ankle brachial index), jeho hodnota pod 0,9 je určující pro ICHDK, hodnota pod 0,5 pak pro kritickou končetinovou ischemii. [6]

Limitací této metody je vyšetření rozsáhle kalcifikovaných tepen, které nejsou stlačitelné ani po nafouknutí manžety nad 250 mmHg, tepny s mediokalcinózou u diabetiků a u pacientu po bypassech na dolních končetinách, kde je metoda považována za málo senzitivní. [6]

3.3.3 Kapilaroskopie

Kapilaroskopie je používána ke zhodnocení mikrocirkulace, mikroskopicky dochází k hodnocení hustoty a charakteru kožní kapilární sítě, charakteru vinutí kliček, jejich šíře, případně okolní edém, hemoragie apod. Nejčastěji takto hodnotíme akrální části, tedy řečiště na ruku, nohu a nehtová lůžka. Při použití fluorescenčních metod je pak možné sledovat i rychlost proudění krve, kapilární tlak a permeabilitu kapilár. Získaný obraz je patologický při onemocněních pojiva, vaskulitid, ale i u pokročilé aterosklerózy a diabetické mikroangiopatii. [6]

3.3.4 Ultrasonografické vyšetření

Ultrasonografie zpravidla využívá sond o frekvenci 2,5–10 MHz. Umožňuje zobrazit jednotlivé tkáně a pomocí dopplerovských technik také tok krve. [5] Dále se uplatňuje v morfologickém zhodnocení stěny tepny či při chirurgických cévních rekonstrukcích, kdy umožňuje kvalitní zobrazení polohy a funkce bypassu či kvantifikaci významnosti stenózy. [6]

Standardně je využíván tzv. triple mód, tedy kombinace klasického zobrazení v B-modu (anatomické zobrazení tkáně ve spektru šedi různých odstínů) doplněné o dvě modalities dopplerovského mapování. První z nich je ta, jenž umožňuje detekci směru a rychlosti pohybu červených krvinek (červená barva značí směr k sondě, modrá směr od sondy, světlejší barva značí vyšší rychlost toku). Druhou modalitou je tzv. pulzní doppler, který slouží ke kvantifikaci rychlosti toku krve, směr a rychlost proudění jsou vyjádřeny tzv. spektrální křivkou, kdy amplituda křivky ukazuje na rychlost proudění, směr křivky vzhledem k základní linii směr proudění. Horizontální osa X je pak časovou linií. [6]

3.3.5 Laser – doppler flowmetrie

Jedná se rovněž o metodu používanou k hodnocení mikrocirkulace, podobně jako při ultrasonografii i zde je využíván dopplerovský jev. K vyšetření se používá helium-neonový laser, který proniká jen

do vrchních vrstev kůže (do 1,5 mm). [5] Vlnění, které je vysíláno, se odráží od elementů v kapilárách, mění svoji frekvenci a díky frekvenčnímu posunu je možno zhodnotit průtok řečištěm. Této metody je v modifikaci, kdy se přístroj nedotýká kůže, využíváno při hodnocení trofických defektů. [6]

3.3.6 Pletysmografie / fotopletysmografie

Metoda pracuje na principu odraženého infračerveného záření od krevních elementů. V tkáních bez hemoglobinu je pak emitované červené světlo absorbováno nebo volně propuštěno, mikrocirkulaci tedy hodnotíme na principu zpětné detekce infračerveného záření a jeho intenzity. V praxi je využívána hlavně prstová fotopletysmografie k posouzení perfuze akraálních oblastí končetin, a to především u pacientů, u kterých nemá výpovědní hodnotu měření kotníkových tlaků (jedná se zejména o diabetiky s mediokalcinózou). [6]

3.3.7 Hodnocení tuhosti arteriální stěny a endoteliální dysfunkce

Tuhost arteriální stěny hodnotíme pomocí dvou ukazatelů. Jedním je PWV (pulse wave velocity) a druhým augmentační index. Metodou se stanovuje rychlost propagace pulsové vlny cévním řečištěm, která stoupá při zvýšené tuhosti cévní stěny. Augmentační index je hodnocen metodami využívajícími aplanační tonometrie, kdy ze tvaru pulzové vlny lze odvodit centrální arteriální tlak a jeho navýšení odraženou komponentou pulzové vlny. [5, 6]

K hodnocení endoteliální funkce je využíváno hodnocení vazodilatace, kdy je jako podnět k vazodilataci používány látky ji navozující. Nevýhodou je invazivní charakter tohoto vyšetření, v praxi je tedy používán neinvazivní postup, kdy je vazodilatace provokována přechodnou ischemií, následně je pak hodnocena pomocí různých technik, jako je ultrazvuk, doppler či pletysmografie. [5, 6]

3.3.8 Transkutánní tenze kyslíku

Tato metoda napomáhá k hodnocení perfuze kání, stanovení tenze kyslíku se provádí skrze kůži s kapilárními plexy, využívána je pak zejména při hodnocení perfuze u chronické končetinové ischemie. Za významně patologickou hodnotu považujeme tcO_2 pod 30 mmHg. [6]

3.3.9 CT angiografie, magnetická rezonance

Tyto metody jsou nyní jedny z nejčastěji používaných k detekci cévních onemocnění, umožňují přesné zobrazení stenóz, tepenných uzávěrů či aneurysmat. CT vyšetření je považováno za zlatý standard v diagnostice disekce, ruptury aneurysmatu či plicní embolie, dále pak zjištění cévní mozkové příhody.

Limitace CT vyšetření je v podání jodové kontrastní látky a radiační zátěži. Oproti tomu vyšetření magnetickou rezonancí je limitováno použitím magnetického pole, které je kontraindikováno u pacientů s kovovými implantáty, kochleárními implantáty či kardiostimulátory. [6]

3.3.10 Angiografie

Při angiografickém vyšetření je do cévního řečiště injikována kontrastní látka, rizika plynou z invazivního přístupu, možnosti anafylaxe či selhání ledvin. Obecně je aktuálně používáno, pokud je předpoklad, že bude po diagnostice následován terapeutický výkon, typicky angioplastika, implantace stentu či trombektomie. [6]

3.3.11 Intravaskulární ultrazvuk (IVUS)

Jedná se o poměrně novou metodu používanou k získání příčného ultrazvukového obrazu posuzované cévy pomocí speciálně upraveného katetru zakončeného ultrazvukovou sondou. Lze při něm hodnotit stěnu cévy, šíři lumina, a především aterosklerotické pláty či disekce intimy. Aktuálně je nejvyužívanější při intervenčních kardiologických výkonech. [6]


3.4 Zobrazení kalcifikací při diagnostických metodách

Kalcifikace jsou nejlépe zobrazitelné při CT, MR, ultrazvukovém a rentgenovém vyšetření. Z invazivních metod při angiografii. Kalcifikace jsou na rentgenových snímcích dobře viditelné v případě, že jsou rozsáhlé, často lze pozorovat zvláště na nativním snímku břicha kalcifikace v abdominální aortě a větvení ilických tepen. [6]

Při ultrazvukovém vyšetření kalcifikace odrážejí ultrazvukové vlnění, zobrazují se hyperchogenně, tedy bíle, často za strukturou vzniká hypoechogenní stín. Tímto mohou působit komplikace zejména při dopplerovském vyšetření v hodnocení průtoku v místě přítomnosti těžce zvápenatělých plátů. [6]

Při CT vyšetření pro samotné vyhledání a hodnocení kalcifikací existují speciální softwarové aplikace, které kalcifikace definují jako léze o určité hustosti, tzv. denzitním rozhraní (od 130 HU výše). [6] Pokud je však počet kalcifikací významný, mohou vznikat artefakty a okolní tkán je tak hůře hodnotitelná (tzv. blooming). [6]

Nejčastějším vyšetřením magnetické rezonanci je MR angiografie, MR angiografii tepen lze provádět buď nativně, metodou time-of-flight a metodou fázového kontrastu, či po aplikaci kontrastní látky. Oproti CT nejsou na MR artefakty od kalcifikací, MR má však nižší prostorovou rozlišovací schopnost. V základní sekvenci jsou kalcifikace na MR asignální, zobrazují se tedy černě, v sekvenci SWI (susceptibility weighted imaging) je možno detekovat kalcifikace za pomoci fázového zobrazení. [6]



Obrázek 3.3: CT snímek břišní oblasti s implantovaným stentem na arteria iliaca communis. Zdroj vlastní.

Kapitola 4

Zpracování obrazu cévního systému

Abychom dosáhli kvalitního obrazu, resp. obrazu s požadovanými parametry, je nutné provést několik po sobě následujících kroků.

Prvním krokem zpracování obrazu je snímání a digitalizace obrazu. Obraz je uložen do počítače v číselné formě. Vstupní informace může být z kamery případně skeneru. Další možnost jsou spektrální složky – nejčastěji zelená, červená a modrá při barevném snímání obrazu. Díky digitalizaci se převádí vstupní analogový signál do diskrétního tvaru. Vstupní signál je popsán funkcí $f(x, y)$. Přičemž proměnné dané funkce znamenají souřadnice v obraze funkční hodnota odpovídá například jas. Každý vstupní signál prochází vzorkováním a kvantováním. Výsledkem je pak matice hodnot popisující obraz. [7]

Dalším základním krokem je předzpracování obrazu. Cílem předzpracování je potlačit jakýkoliv šum a případné zkreslení vzniklé při digitalizaci a následném přenosu obrazu. Někdy při předzpracování se snažíme zvýraznit určité rysy obrazu, které jsou podstatné pro další zpracování, například hledáme hrany. [7]

Dalším krokem postupu zpracování je segmentace. Segmentace umožní v obraze rozlišit jednotlivé objekty. Objekty jsou ty části obrazu, které nás zajímají z hlediska následného zpracování. Pokud je segmentace kvalitní, pak je nosným krokem pro to, abychom porozuměli obsahu obrazu, a také je základem pro vyšší metody zpracování obrazu. [7]

4.1 Konvoluce

Konvoluce hraje důležitou roli při lineárním přístupu zpracování obrazu. Konvoluce dvourozměrných spojitých funkcí f a h je definována integrálem

$$f(x, y) * h(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x - a, y - b) h(a, b) da db \quad (4.1)$$

kde funkce $h(x, y)$ je nazývána konvolučním jádrem.

Při užívání konvoluce v digitálním obraze se jedná o tzv. diskrétní konvoluci, jež je diskrétní dvourozměrnou podobou výše zmíněného vztahu

$$I(x, y) * h(x, y) = \sum_{i=-k}^k \sum_{j=-k}^k I(x - i, y - j) h(i, j) \quad (4.2)$$

kde $I(x, y)$ figuruje jako diskrétní obraz a $h(x, y)$ je jádrem konvoluce. [7]

4.2 Lineární filtrace

Jedná se o diskrétní konvoluci. Jádro konvoluce je definováno jako lokální okolí. Obvykle se používá pravoúhlé okolí. pro toto použití mluví fakt, že okolí je praktické mít symetrické vůči středovému elementu. Obvykle se volí množiny lichých přirozených čísel. [7]

Lineární filtry, též nazývané jako konvoluční lineární operace jsou použity pro vyhlazování hran a také k detekci hran. takovéto vyhlazování obrazu pomáhá potlačit vyšší frekvence šumu. Obvykle však dochází také k potlačení jiných, mnohdy žádoucích náhlých změn jasu. Toto má za následek rozmazání hran. [7]

Příkladem vyhlazování je průměrování. Průměrování znamená, že každému bodu je přiřazen jas, který je průměrem jasů ve zvoleném okolí v jeho původní hodnotě. Také můžeme zvýšit hodnotu konvolučního jádra, aby se lépe daly odhadnout vlastnosti šumu s Gaussovým rozdělením. [7]

Další možností po průměrování je gradientní operace. Tady naopak dochází ke zvýraznění vyšších frekvencí. Při tom jsou zvýrazněné ty části obrazu, které mají náhlou změnu jasu. Tímto se dosáhne zvýraznění hran v daném obraze. Při tomto postupu však dochází k tomu, že jsou jako vedlejší efekt také zvýrazněny šumové body, takže metody vyhlazování a ostřicí operace v daném obraze jsou protichůdné. Je však možné tyto metody pomocí algoritmů kombinovat. [7]


Kapitola 5

Úvod do segmentace obrazu

Segmentace obrazu je rozdělení obrazu do částí, které obsahují jednotlivé objekty v obraze. Je to jeden z nejdůležitějších kroků jakékoliv analýzy obrazu. Informaci o rozdělení obrazu na segmenty využívají algoritmy pro zpracování obrazu.

Segmentace obrazu je využívána k extrahování zájmových objektů z digitálního obrazu. Je to metoda, respektive skupina metod založená na různých principech zpracování digitálního obrazu, kdy hlavním účelem je rozdělení obrazu na oblasti, jež sdílí určité vlastnosti. Digitální obraz se skládá z pixelu, což je základní obrazový element. Vlastnosti pixelu jsou jas a barva. Podle těchto parametrů můžeme určovat jeho sounáležitost s dalšími pixely, jež poté tvoří např. již zmíněný zájmový segment.

Využití segmentace je velmi široké. Například v počítačovém vidění, v medicíně při rozlišování zdravé a patologické tkáně, při detekci retinálních cév či detekci a následnému výpočtu kalcifikačního skóre cév. Dalším příkladem také může být využití segmentace při detekci a rozpoznávání obličejů, ať už využíváno sociálními sítěmi, či v kriminalistice apod.



Obrázek 5.1: Příklad histogramu medicínského snímku cév břišní dutiny. Zdroj vlastní.

Prerekvizita k extrakci zájmového objektu, tudíž samotné segmentaci je digitální snímek, jež je obrazová informace exportovaná do číslicové formy. Forma obrazových dat je matice o libovolné velikosti, jež obsahuje diskrétní hodnoty. Tyto hodnoty znázorňují jasovou úroveň pixelu. V případě barevného snímku pixel také nese informaci o barvě.

Na obrázku 5.1 je nativní snímek spolu s histogramem snímku. Histogram je hojně využívaným statistickým zobrazením, jež je hojně využíván při obrazových operacích.

Segmentaci obrazu dělíme na tři základní typy dle dominantních rysů.

- Regionálně orientovaná segmentace
- Iterační deformovatelné křivky
- Hranové detektory

Hranové detektory jsou založené na hledání prvku diskontinuity a tím vytvářejí hranice regionů. Iterační deformovatelné křivky jsou známější pod pojmem aktivní kontury, které se dle vnitřních a vnějších energií asimilují do tvaru objektu. Tato práce se zaměřuje na regionální segmentaci, o které bude dále pojednáváno. [8]

5.1 Definice segmentace

Segmentace obrazu je dána funkcí $f(x, y)$ a obraz je dělen na podobrazy R_1, R_2, \dots, R_n takovým způsobem, že podobrazy splňují následné podmínky [7]:

1. $\bigcup_{i=1}^n R_i = f(x, y)$
2. $R_i \cap R_j = \emptyset, i \neq j$
3. Každý podobraz splňuje jedno, nebo množinu tvrzení:
 - všechny pixely v podobraze R_i mají stejnou úroveň šedi,
 - všechny pixely v podobraze R_i se neliší v úrovni šedi více než o předepsanou hodnotu,
 - standardní odchylka úrovně šedi všech pixelů podobrazu R_i je dostatečně malá, apod.

5.2 Metody segmentace obrazu

Mezi segmentační metody patří již zmíněné prahování a jeho samostatná variace Otsu metoda. Dále také shluková analýza a další. Tyto techniky jsou založené na klasifikaci obrazové jednotky, tj. pixelu, ve dvojrozměrném obrazu, či voxelu, ve trojrozměrném obrazu, na základě jasové úrovně. Za novodobý trend je považováno nahrazení manuální segmentace za automatickou, při které je ovšem

stále velmi důležité mít odpovědně-kompetentní osobu pro kontrolu procesu a správnosti výsledku metody.

5.3 Prahování

Prahování, či anglicky thresholding, je metoda zpracování obrazu, konkrétně metoda segmentace, jež vychází z definování prahů, jež jsou hranicemi segmentačních tříd. Parametry této metody lze definovat kupříkladu pomocí histogramu daného snímku, v kterémžto případě je analyzován tvar a jsou detekovány minima nebo maxima, nebo také dle vizuálně-interaktivního přístupu.

Dle počtu zvolených prahů dělíme tuto metodu na buď binární prahování, tento typ nastává pouze v situaci, kdy je zvolen jen jeden práh, nebo víceúrovňové prahování, anglicky multithresholding, kdy počet prahů musí být více než dva včetně.

5.3.1 Binární prahování

Binární segmentace je nejjednodušší metodou prahování a celkově segmentace. Tato metoda je založena na dělení snímku na dva regiony zvolením jednoho prahu, často označovaného jako T (z anglického threshold). Optimální hodnotu prahu lze vyčíst z histogramu snímku, viz obrázek 5.1. Zvolený práh je možné si představit jako např. záložku v knize, kdy vše před záložkou je rovno hodnotě nula a vše za záložkou je rovno jedné. Tímto je vytvořen binární, resp. černobílý snímek.

Matematický předpis binárního prahování je jednoduchým popisem transformace vstupního obrazu $g(x, y)$ na výstupní $f(x, y)$.

$$f(x, y) = \begin{cases} 1 & g(x, y) \geq T \\ 0 & g(x, y) < T \end{cases} \quad (5.1)$$

Z rovnice (5.1) lze vyčíst, že byl zvolen jen jeden práh, tudíž se musí zákonitě jednat o binární prahování. Dále lze vyčíst, že všechny hodnoty pixelů pod prahovou úrovní T budou nastaveny na hodnotu nula, a všechny ostatní, tj. pixely s hodnotou jež je větší než námi zvolený práh T budou nastaveny do hodnoty jedna. Hodnota jedna pro nás bude znamenat oblast zájmu, a naopak hodnota nula pro nás bude znamenat pouze jakési pozadí, jež pro nás není ničím zajímavé (viz Obrázek 5.2).

5.3.2 Adaptivní prahování

Tato metoda využívá rozdělení obrazu do jednotlivých částí. Nejlépe čtverců, případně obdélníků. V každé dané oblasti lze nastavit hodnotu prahu zvlášť. Problematické jsou hranice těchto segmentů.



Obrázek 5.2: Aplikace binární segmentace na medicínský snímek cév břišní dutiny. Vlevo nativní snímek, střed segmentován normalizovaným prahem $T = 0,25$, vpravo prahování při $T = 0,5$. Zdroj vlastní.

Multi threshold, jinak také víceúrovňové prahování. V této metodě se stanoví několik množin, které nemají průnik a následně se určuje, jestli hodnota daného pixelu leží mezi danými prahy T_n a T_{n+1} , vztahový vzorec (5.2) [9].

$$\begin{array}{ll}
 f_{(i,j)} = 1 & g_{(i,j)} \geq T_1 \ \& \ g_{(i,j)} < T_2 \\
 f_{(i,j)} = 2 & g_{(i,j)} \geq T_2 \ \& \ g_{(i,j)} < T_3 \\
 f_{(i,j)} = 3 & \text{je-li } g_{(i,j)} \geq T_3 \ \& \ g_{(i,j)} < T_4 \\
 \vdots & \vdots \\
 f_{(i,j)} = n & g_{(i,j)} \geq T_n
 \end{array} \quad (5.2)$$

5.3.3 Otsu metoda

Otsu metoda je modifikovaná metoda prahování, která je řazena mezi statistické metody z důvodu pracování na základě statistického parametru rozptylu, jež je ukazatelem variability rozdělení, konkrétně rozdělení pixelů v obraze. Tato metoda využívá klasifikaci pixelů do jednotlivých segmentačních regionů, a tudíž je jedna z metod multiregionální segmentace, kdy platí že při definování počtu tříd n vznikne $n + 1$ regionů. Otsu metoda pracuje na bázi prahování histogramů, čímž se definuje počet oblastí. Hledá se taková segmentační třída, jejíž rozptyl bude co nejmenší, což bude značit optimálně zvolený práh. [10]

Optimální prahová hodnota je získána pomocí vnitřního rozptylu (v angličtině intra-class variance) a mezi-rozptylu (v angličtině inter-class variance). Zvyšujícím se počtem tříd v obraze se rapidně zvyšuje časová náročnost víceúrovňového prahování. [11] Mezi rozptyl je dán vztahem:

$$\sigma_B^2 = W_b \cdot W_f \cdot (\mu_b - \mu_f)^2 \quad (5.3)$$

Kde:

W_b : je váha pozadí

E_f : je váha popředí

μ_b : je průměrná hodnota intenzity pozadí

μ_f : je průměrná hodnota intenzity popředí

Rovnice pro výpočet zmíněných jednotlivých prvků jsou následovné (rovnice 5.4-5.7):

$$W_b = \sum_{i=1}^k \frac{n_i}{N} \quad (5.4)$$

$$W_f = \sum_{i=k+1}^M \frac{n_i}{N} \quad (5.5)$$

$$\mu_b = \sum_{i=1}^k \frac{n_i \cdot i}{N_k} \quad (5.6)$$

$$\mu_f = \sum_{i=k+1}^M \frac{n_i \cdot i}{N - N_k} \quad (5.7)$$

V těchto rovnicích značí M pixely snímku, jež mají odstíny šedi s intervalem $[0, 1, \dots, M]$, i je odstínem šedi, n_i je četnost pixelů v určitém odstínu a N je celkovým počtem pixelů, což lze vypočítat pomocí následovného vztahu:

$$N = n_0 + n_i + n_M \quad (5.8)$$

Výsledné pixely jsou poté rozděleny na dvě skupiny f jakožto popředí, z anglického front, a b jakožto pozadí, z anglického background, dle prahovací úrovně k . [12]

5.4 Detekce hrany

Vzhledem k tomu, že hrana je vlastně extrémní změna ve funkci jasu, pak je možné použít derivaci. Derivace v místě hrany pak dosahuje extrémních hodnot, čímž se liší od ostatních derivací. Maximální hodnota dané derivace je pak kolmicí na hranu. Pokud použijeme následně konvoluci, jsme schopni danou derivaci aproximovat. Využívají se tzv. hranové operátory. Příklady operátorů k určení hran [9]:

1. Roberts

$$-\begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix} \text{ a } \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix} \quad (5.9)$$

2. Sobel

$$-\begin{pmatrix} -1 & 0 & -1 \\ -2 & 0 & -2 \\ 1 & 0 & 1 \end{pmatrix} \text{ osa } x, \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix} \text{ osa } y, \begin{pmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{pmatrix} \text{ osa } z. \quad (5.10)$$

3. Prewitt

$$-\begin{pmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{pmatrix}^T \text{ detekování na ose } x, \begin{pmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{pmatrix} \text{ pro osu } y \quad (5.11)$$

5.4.1 Metoda prvních derivací

Tato metoda je označována také jako gradientní. Pokud máme oblast homogenní, tzn. že rozdíl jasu není markantní, tak obraz neobsahuje hrany a derivace funkce jasu v této oblasti je nulová. Parciální derivace jsou prováděny pro každou osu zvlášť. Takto je získán vektor. Vektor jako takový nám udává hodnotu velikost a směr, tzv. gradient. Gradient je kolmý na danou hranu, resp. vektor. [9, 13]

Velikost hrany $|\nabla g(i, j)|$ a úhel ψ , který svírá hrana s osou x lze spočítat. K výpočtu jsou využity vzorce 5.12 a 5.13. Z důvodu že je obrazová funkce diskrétní a její derivace je obtížně spočitatelná, je využívána aproximace skrz vhodně zvoleným výpočtem diferenciálu (rovnice 5.14), kde funkce O udává řád chyby výpočtu. Tento předpis je nazýván centrální diferenciální rovnicí. [9]

$$|\nabla g(i, j)| = \sqrt{\left(\frac{\partial g}{\partial x}\right)^2 + \left(\frac{\partial g}{\partial y}\right)^2} \quad (5.12)$$

$$\psi = \arctg\left(\frac{\frac{\partial g}{\partial y}}{\frac{\partial g}{\partial x}}\right) \quad (5.13)$$

$$\Delta f(x) = \frac{(f(x+1) - f(x-1))}{2h} + O(h^2) \quad (5.14)$$

5.4.2 Metoda druhých derivací

Tato metoda využívá vlastnosti, že první derivace dosahuje maximálních hodnot při změně největší intenzity. Druhá derivace naopak při stejných maximálních hodnotách dosahuje hodnoty nula. Následně tedy hledáme místa, kde druhá derivace prochází nulou. Tyto metody jsou citlivé na šum mnohem více, než derivace první. zde se pak může uplatnit metoda následného vyhlazením. Opti-

mální hodnota pak je, pokud je šum eliminován, aniž by byla porušena hrana. [9]

Obraz po druhé derivaci je získán vztahem (5.15)

$$\Delta g(x, y) = \frac{\partial^2 g(x, y)}{\partial x^2} + \frac{\partial^2 g(x, y)}{\partial y^2} \quad (5.15)$$

Výpočet diskretní funkce je realizován vztahem (5.16)

$$\Delta^2 f(x) = \frac{(f(x+1) - f(x-1))}{h^2} - O(h^2) \quad (5.16)$$

Nejrozšířenější jsou zřejmě Laplaceovy operátory. Vlastností těchto operátorů je ten, že důraz je orientován na střed. V tomto případě ale nemůžeme použít výpočet, kde Laplaceův operátor je roven nule. Pro odstranění šumu musíme využít Gaussův filtr. V tomto případě pak určíme konvoluční jádro. Můžeme také volit velikost jádra. Nicméně velikost jádra je přímo úměrná velkým nárokům na jeho výpočet. [7, 9]

Dalším a posledním krokem druhých derivací je určení nulových bodů. Po použití výše uvedených metod musíme určit pro zjištěnou funkci, kde tato funkce prochází nulou. Nicméně i tato metoda má svá úskalí. Pokud je první derivace maximální a druhá derivace je nulová, pak dostáváme detekci hran. Ovšem pokud první derivace je nulová, pak druhá derivace je také nulová. Pak ovšem nedochází k detekci hran, ale homogenní oblasti. V těchto oblastech se ovšem hrany v reálu nevyskytují. [7, 9]

Těmto nesrovnalostem lze ovšem předcházet. Musíme však zvolit jiný způsob detekce. Obvykle se používá masky 2×2 (5.17), která se použije postupně na celý zpracovávaný obraz.

$$\begin{bmatrix} \alpha & \beta \\ \gamma & \delta \end{bmatrix} \quad (5.17)$$

První prvek v masce ze vztahu (5.17), je α středem masky a posuzuje se, zda se změní znaménko vůči ostatním pixelům. Pokud nedojde ke změně znaménka, pokračuje se v detekování obrazu. Pokud ke změně znaménka dojde, pak je daný zkoumaný pixel označen jako možná hrana. [9]


5.5 Metody hledání oblastí

Zde se nedetekují hrany jako v předešlých metodách, ale orientujeme se na homogenní oblasti. Tzn. oblasti se stejnou intenzitou jasu, případně barvou. Nutné je vlastnosti těchto homogenit dopředu

definovat. Tyto metody jsou nepoměrně více odolné proti šumům. Nutností pro tyto metody je, aby každý daný pixel patřil do jednoznačné oblasti, přičemž se dané oblasti nesmějí překrývat, tedy oblasti musí být bezprůnikové.

5.5.1 Region growing

Region growing neboli metoda narůstání oblastí. Tato metoda je vlastně opačným postupem metody split and merge. V prvním kroku se určí body daného obrázku – viz vlevo na obrázku 5.3. Tyto body se pak začínají testovat tak, že se vyhodnocuje, zda splňují kritéria dopředu určená a zda tedy vytváření homogenní oblast. Nicméně počáteční body pro danou operaci je dosti obtížné určit. Výsledek této metody je závislý na pořadí spojování. [7, 14]




Obrázek 5.3: Princip metody region growing. Převzato z [14].

5.5.2 Region split and merge

Metoda region split and merge, neboli metoda dělení a spojování, pracuje s obrazem tak, že se daný obraz postupně dělí na části, které se nepřekrývají. Obvykle se dělí na čtverce nebo obdélníky. Pokud dělíme na čtverce, pak výsledku říkáme quad-tree neboli „čtyřstrom“ - viz obrázek 5.4.

Po rozdělení se použije kritérium pro stejnorodost dané oblasti, resp. pro její homogenitu. Po testu takové oblasti můžeme zjistit, že buď oblast splňuje, nebo nesplňuje zadaná kritéria. Pokud nesplňuje, pak se daná oblast dále dělí. Pokud oblasti kritériem vyhoví, dělení oblasti nepokračuje. Dělení může být opakováno až do rozdělení na jednotlivé pixely, případně může být omezeno počtem dělení, tzv. vnořených kroků. [7, 14]



Obrázek 5.4: Princip hierarchie segmentace split and merge. Převzato z [7].

5.6 Hybridní metody

Hybridní metody jsou metody složené z různých prvků již zmíněných algoritmů, a proto je nelze řadit striktně do zmíněných kategorií.

5.6.1 Watershed transformace

Tuto transformaci lze řadit mezi regionálně založené segmentační metody. Typově je řazena mezi morfologické metody, a to z důvodu svého základního principu, respektive myšlenky na niž je vystavěna. Obraz je pojat jakožto topografický reliéf, jež je postupně zaplavován. [15, 16]


Povodí jsou z počátečních bodů, tedy lokálních minimy zaplavována. Tam, kde by se pomyslná voda měla možnost slít jsou vytvořeny hráze. Zaplavování je ukončeno, kdy je dosaženo maxima, tím je myšleno dosažení nejvyššího bodu. Výsledek je snímek segmentovaný na oblasti, tj. povodí oddělených hrázemi. [15, 16]

Tato metoda produkuje nadměrné množství regionů, což je obvykle následně řešeno spojováním oblastí patřících do stejné struktury. Nadměrné segmentaci se dá předejít použitím vhodného předzpracování, což může být kupříkladu vyhlazení Gaussovým filtrem. [15, 16]

Výhodou je osvědčenost metod. Naopak nevýhodou je nutnost dalšího zpracování, a to proto, že když je snímek zašuměný, tak tato metoda vyváří vysoký počet regionů. [15, 16]

5.6.2 Wavelet transformace

K segmentaci pomocí waveletovy transformace je nutno použít dvourozměrné diskrétní waveletovy transformace s diskrétním časem. K dekompozici obrazu užíván rekurzivní pyramidový algoritmus, kdy se data filtrují zvlášť po řádcích a sloupcích. Algoritmus je znázorněn na obr. 5.5. [17]



Obrázek 5.5: Algoritmus dvourozměrné waveletovy dekompozice. Převzato z [17].

Data na výstupu projdou filtry dolní a horní propusti. Poté jsou zpracovávány po řádcích, přičemž je vynechán každý druhý prvek. Následně výsledek opětovně projde filtry. Dalším krokem je poté zpracování sloupců stejným způsobem jakožto dříve řádků. [17]

Jeden krok takovéto dekompozice vyprodukuje následující čtyři koeficienty:

- A_1 – aproximační
- H_1 – horizontální
- V_1 – vertikální
- D_1 – diagonální

Další stupeň dekompozice by byl proveden stejným postupem. Vstupem by ovšem nebyl původní snímek, ale aproximační koeficienty. Zbytek koeficientů by byl uchován.

Koeficient A_n po filtraci obsahuje hlavně hodnoty nízkých frekvencí, a tudíž nese nejvyšší energii, jinak také informaci. Stejně jako u ostatních signálů, nízkofrekvenční složky nesou základní informace o signálu a vysokofrekvenční složky signálu uchovávají detailní informace, jež mohou být u obrazových dat kupříkladu informace o detailech a hranách na snímku. [17]

5.7 Metody deformovatelných modelů

Metody deformovatelných modelů se dělí na dva typy. Prvním typem jsou parametrické aktivní kontury a druhým typem jsou geometrické aktivní kontury. Zástupci těchto typů jsou aktivní kontury a metoda level-set, respektive. Geometrické aktivní kontury mají několik výhod oproti parametrickým, kde jedna z hlavních je možnost segmentace vícero objektů najednou. [18]

5.7.1 Aktivní kontury

Pro výraz aktivních kontur se používá také název snakes. Je to metoda, při které se postupně tvarují kontury až ke hraně objektu v daném obraze. Tento model používá deformaci:

- Vnitřních sil
- Vnějších sil
- Obrazových sil

Vnitřní síly kontrolují hladkost průběhu. Vnější síly pak jsou výsledkem počátečního umístění kontury a obrazové síly směřují tvarování kontury k hraně objektu. Kontura, která je diskrétní

$$\mathbf{v}_n = [x_n, y_n], \text{ pro } n = 0, 1, \dots, N \quad (5.18)$$

Výsledná pozice této aktivní kontury je pak totožná s lokálním minimem energie kontury.

$$E_S = \sum_{n=1}^N E_N \{\mathbf{v}_n\} + \sum_{n=1}^N E_I \{\mathbf{v}_n\} + \sum_{n=1}^N E_r \{\mathbf{v}_n\} \quad (5.19)$$

Kde:

E_S : je vnitřní energie kontury (ohyb, zlom)

E_I : je energie v obraze


E_R : je energie omezení

Standardní algoritmus nedosahuje dostatečné kvality, když jsou kontury složitější, z důvodu vytváření falešných kontur a neschopnosti rozeznání prudkých zlomů hranic kontury. Tento problém byl částečně vyřešen modifikovanou verzí od L. Ji a H. Yan [19]. Výhodou této metody je vhodnost užití pro komplexní tvary, naopak nevýhodou je nutná ruční inicializace. [7]

5.7.2 Metoda level-set

Metoda level-set užívá podobného přístupu jako předešlá metoda aktivních kontur. Jedná se o geometrickou aktivní konturu.

Metoda vyvíjí kontury ve dvou rozměrech anebo povrch v případě tří rozměrů. Křivka je prezentována tzv. nulovou hladinou. Tato hladina je vlastně řez v rovině xy . Používá se level set funkce, která přiřadí každému bodu dané roviny xy výšku u nad nulovou hladinou, viz obrázek 5.6. Metoda je založená na tom, že tvar křivky neměníme přímo jako u metody aktivních kontur, ale řídí se prostřednictvím výše uvedené funkce. Tato metoda se používá pro objekty se složitými tvary, jelikož je pro komplexnější tvary účinnější. Také umožňuje stanovit podmínky křivosti v závislosti na znalosti objektu. [7]



Obrázek 5.6: Příklad funkce level-set pro uzavřenou křivku C ve 2D. Převzato z [7].


5.8 Metoda shlukové analýzy

Metodu shlukování, jinak také clustering, považujeme za pokročilou adaptivní prahovací metodu. Shlukovací metody dělíme na hierarchické a nehierarchické. Mezi nehierarchické metody patří metoda K-means, Fuzzy C-means, nebo neuronové sítě, jež jsou vystavěné na základě umělé inteligence.

5.8.1 K-means

Segmentační metoda K-means přiřazuje jednotlivé body k segmentačním třídám, ke kterým dle Euklidovy metriky přísluší. Klasifikace příslušnosti je realizována skrz hledání minimální vzdálenosti mezi zvoleným těžištěm a pixelem. Tuto metodu je možné použít ke shlukování dle podobných vlastností.

Obrázek 5.7 ilustruje lekce odlišitelné shluky, respektive ideální stav, jemuž se chceme přiblížit vhodnou volbou příznaků. Regionální segmentace vyžaduje rozdělení do jednotlivých segmentačních tříd, resp. klasifikaci. Toto je nutné k vytvoření indexační matice. Každé třídě je přidělen index, jež je také přidělen oblasti s podobnou vlastností. Tento proces využívá klasifikačních etalonů. Etalon je n -rozměrný vektor přepočítávaný na základě vzdálenosti.



Obrázek 5.7: Příklady výsledky shlukování. a) správný počet shluků, správně klasifikované body; b) nesprávný počet shluků; c) správný počet shluků, některé body špatně klasifikovány. Převzato z [12].

Vzdálenosti mohou být Hammingova, Minkovského, Čebyševova nebo nejužívanější Euklidovu. Euklidova metrika měří vzdálenost bodů v prostoru příznaků. Označíme-li metriku D a příznakové vektory \vec{x} respektive \vec{y} , bude výsledná vzdálenost $D(\vec{x}, \vec{y})$. [12]

$$D(\vec{x}, \vec{y}) \geq 0 \quad \forall \vec{x}, \forall \vec{y} \quad (5.20)$$

$$D(\vec{x}, \vec{y}) = D(\vec{y}, \vec{x}) \quad \forall \vec{x}, \forall \vec{y} \quad (5.21)$$

$$D(\vec{x}, \vec{x}) = 0 \quad \forall \vec{x} \quad (5.22)$$

Pro Euklidovu metriku platí, že je nezáporná a symetrická dle vztahu (5.20) a (5.21). Vzdálenost bodu od sebe sama je nulová, viz vztah (5.22). Popis metriky je následovný:

$$D(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (5.23)$$

Kde:


$D(\vec{x}, \vec{y})$: je výsledná vzdálenost

n : je dimenze prostoru

Obrázek 5.8 ilustruje Euklidovu vzdálenost ve dvourozměrném prostoru.

Metoda K-means je jednou z nejjednodušších algoritmů, jež provádí nesupervizované učení. Jedná se o shlukovací metodu, jež má za účel rozdělit data ze souboru do předem specifikovaného počtu skupin. Metoda klasifikuje danou sadu dat do počtu disjunktních shluků. [20]

Algoritmus se skládá ze dvou samostatných fází. V první fázi se vypočítávají k centroidy, tj. těžiště, a ve druhé fázi je každý bod setu dat přiřazen do nejbližšího centroidu na základě vzdále-



Obrázek 5.8: Princip Euklidovy metriky. Převzato z [12].

nosti. Vzdálenost je nejčastěji vypočítávána Euklidovskou metrikou, jak už bylo zmíněno. Jakmile je seskupování hotové, je započata rekalkulace centroidu každého shluku. Těžiště pro každý shluk je bod, ve kterém je součet vzdáleností od všech objektů ve shluku co nejmenší. K-means je tedy iterativním algoritmem. [20]

Uvažujme nad snímkem s rozměry $x \times y$, který má být nasegmentován do k shluků. Nechť $p(x, y)$ jsou vstupní pixely k segmentaci, a c_k středy shluků. Algoritmus k-means bude následovat postup [20]:

1. Inicializace počtu k shluků a centroidu
2. Pro každý pixel v obraze, vypočti Euklidovskou vzdálenost d mezi centroidem a pixelem užitím následujícího vztahu

$$d = \|p(x, y) - c_k\| \quad (5.24)$$

3. Přiřaď všechny pixely nejbližšímu centroidu na základě vzdálenosti
4. Po přiřazení všech pixelů, rekalkuluj novou pozici centroidu dle následujícího vztahu

$$c_k = \frac{1}{k} \sum_{y \in c_k} \sum_{x \in c_k} p(x, y) \quad (5.25)$$

5. Opakuj proces, dokud není tolerance nebo chybová hodnota přijatelná
6. Přetvoř nashlukované pixely do obrazu

Kvalita výsledného shlukování je dependentní na výběru původního centroidu. Při využití této metody je také nutné zvážit výpočetní složitost, jelikož k-means závisí na objemu dat, počtu shluků a také počtu iterací. [20]

5.8.2 Fuzzy c-means

Metoda fuzzy c-means je založena na hledání těžišť shluků pomocí iterativního opravování pozic. Tato metoda je flexibilnější z důvodu možnosti částečné náležitosti shluků.

Základní metoda shlukování hard c-means je postavena na identifikaci C těžišť pro každý shluk. Pozice těchto těžišť je velmi důležitá jelikož přímo ovlivňuje výsledek shlukování. Tato metoda si klade za cíl minimalizování funkce ve formě kvadrátu chyby. [21]

$$E = \sum_{j=1}^C \sum_{i=1}^N \|x_i^{(j)} - c_j\|^2 \quad (5.26)$$

Kde:

C : je centroid

N : je počet vzorků

x_i : je datový vzorek

c_j : je nejbližší těžiště shluku

$\|x_i^{(j)} - c_j\|^2$: je vzdálenost mezi N a x_i

Chybová funkce, jež je využívána při hard c-means, viz (5.26), musí být rozšířena z důvodu flexibility. Funkce bude tedy vypadat následovně:

$$E = \sum_{j=1}^C \sum_{i=1}^N \mu_{ij}^k \|x_i^{(j)} - c_j\|^2 \quad (5.27)$$

Kde:

μ_{ij} : je fuzzy členství vzorku x_i

x_i : je datový vzorek (pixel)

c_j : je nejbližší těžiště shluku

k : je konstanta definující neostrost výsledných oddílů

E může dosáhnout globálního minima, jestliže pixelům v okolí centroidu korespondujícího shluku je přiřazena vyšší hodnota členství, a naopak vzdálenějším pixelům je přiřazena nižší hodnota členství. Funkce výpočtu hodnoty členství (5.28) a těžišť shluků (5.29) jsou následovné [21]:

$$\mu_{ij} = \frac{1}{\sum_{m=1}^C \left(\frac{\|x_j - c_i\|}{\|x_j - c_m\|} \right)^{2/(k-1)}} \quad (5.28)$$

$$c_i = \frac{\sum_{j=1}^N \mu_{ij}^k x_j}{\sum_{j=1}^N \mu_{ij}^k} \quad (5.29)$$

Jednotlivé kroky, jež jsou využívány při fuzzy c-means obrazové segmentaci:

Krok 1 : Inicializace těžiště shluku c_i , nechť $t = 0$.

Krok 2 : Inicializace funkce fuzzy členství dle rovnice (5.28).

Krok 3 : Nechť $t = t + 1$, vypočti nové těžiště shluku c_i pomocí rovnice (5.29).

Krok 4 : Opakuj krok 2 a 3 až do konvergence.

Kapitola 6

Úvod do realizace práce

Předmětem této práce bylo nastudování esenciálních aspektů zobrazovacích metod pro zobrazování cévního systému (viz kapitola 4). Dále pak nastudování fyziologie a patologie cévního řečiště s orientací na cévní kalcifikace (viz kapitoly 2 a 3). Bylo nutné provést řešení regionálních segmentačních metod pro identifikaci cévního systému z obrazových dat (viz kapitola 5). Následný výběr testovacích dat z poskytnuté datové báze obrazových dat z variabilních obrazových systémů. Poté bylo vytvořeno simulační prostředí pro komparativní analýzu vybraných segmentačních algoritmů s cílem identifikace cévního systému včetně patologických nálezů.

Ve vytvořeném uživatelském prostředí bylo provedeno dávkové kvantitativní testování robustnosti segmentačních algoritmů na reálných obrazech. Následně byla provedena extrakce a statistická analýza příznaků cévního systému se zaměřením na kalcifikace.


6.1 Vstupní datasety

Jako vstupní nativní snímky byly k dispozici snímky z CT a MRI, a to z oblasti dolních končetin, abdominální a pelvická oblast, hlava a krk. Specifikace těchto snímků jsou rozepsány v tabulce 6.1.

Tabulka 6.1: Specifikace vstupních testovacích dat z CT a MRI. Zdroj vlastní.

Dataset	Snímky	Rozlišení [px]	Počet	Formát	Barevný model
CT	Dolní končetiny	1024x1024	4	.jpg	RGB
	Abdom. a pelvická oblast		3		
MRI	Dolní končetiny	1067x1046	3	.jpg	Monochrom.
	Abdom. a pelvická oblast		2		
	Hlava a krk	640x640	2		

Vstupní nativní testovací snímky z datasetu měly podobu, jež znázorňuje obrázek 6.1.



Obrázek 6.1: Testovací snímky datasetů. A: CT snímek abdominální a pánevní oblasti; B: CT snímek dolní končetiny; C: MRI snímek hlavy; D: MRI snímek abdominální a pánevní oblasti. Zdroj vlastní.

Kapitola 7

Šumové generátory a jejich aplikace

První fáze praktické části se zaměřuje na umělé zašumění medicínských snímků. Tento krok je realizován z důvodu účelné degradace obrazové informace pro pozdější vyhodnocení robustnosti segmentačních metod. Hodnocení účinnosti a kvality užitých segmentačních metod je realizováno skrz porovnávání segmentovaných nativních dat s degradovanými, respektive uměle zašumenými snímky pomocí později zmíněných generátorů. Evaluační parametry, jimž je věnována kapitola 9 zajišťují kvalitativní vyhodnocení.

Každý snímek obsahuje jisté množství šumu, jež je možné identifikovat na základě jeho původu. Šum, jakožto nežádoucí, ovšem nedílná složka, kterážto degraduje kvalitu snímku, vzniká například snímacím zařízením či vlhkostí nebo teplotou, jež jsou obecně klasifikovány jakožto vnější vlivy.

7.1 Gaussův šum

Gaussův šum je statistický šum, jež má funkci hustoty pravděpodobnosti stejnou jako u normálního rozdělení, kteréžto je také známo jako Gaussovo rozdělení. Tento šum ovlivňuje každý pixel snímku a není složitý na modelaci, což přispívá k jeho snadnému odstranění. Gaussův šum jinak tak nazýván jako elektronický šum, z důvodu vzniku v zesilovačích či detektorech, je způsoben přírodními zdroji. Tyto zdroje jsou například tepelná vibrace atomu nebo diskrétní povaha záření teplých předmětů. Tento šum ovlivňuje snímek v každém jeho pixelu, ale není složité ho odstranit. Ovlivňuje snímek hodnotami v šedém spektru. Gaussův šum je tvořen dvěma parametry, prvním je střední hodnota μ a druhým je rozptyl σ^2 . [8, 22]

Obrázky 7.1 a 7.2 jsou příkladem aplikace Gaussova šumu na medicínský snímek. 7.1 byl získán pomocí CT a obrázek 7.2 pomocí MRI.

Následná rovnice je matematickým předpisem Gaussovy distribuce.

$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (7.1)$$

Kde:

x : je jasová intenzita šumu


μ : je střední hodnota

σ^2 : je rozptyl

Obrázek 7.1 demonstruje vliv Gaussova šumu na medicínský snímek při různých intenzitách.




Obrázek 7.1: Aplikace Gaussova šumu na medicínský snímek cév břišní dutiny získaný pomocí CT. Vlevo nativní snímek, střed zašuměn parametry $\mu = 0,01$ a $\sigma = 0,01$, vpravo silnější zašumění při $\mu = 0,1$ a $\sigma = 0,02$. Zdroj vlastní.



Obrázek 7.2: Aplikace Gaussova šumu na medicínský snímek cév dolních končetin získaný pomocí MRI. Vlevo nativní snímek, střed zašuměn parametry $\mu = 0,01$ a $\sigma = 0,01$, vpravo silnější zašumění při $\mu = 0,1$ a $\sigma = 0,02$. Zdroj vlastní.

Z obrázku 7.3, jež znázorňuje PDF Gaussova šumu je viditelné, že 70 % až 90 % obrazové informace, resp. pixelů je degradováno v oblasti mezi $\mu - \sigma$ a $\mu + \sigma$. [23]



Obrázek 7.3: Hustota rozdělení pravděpodobnosti, anglicky abrevitováno PDF, Gaussova šumu. [23]

7.2 Salt and Pepper šum

Šum Salt and Pepper je označován jakožto impulzní šum. Impulzní šum je velmi častý v digitálních obrazech. Šum je způsoben chybami v přenosu dat, kdy jsou poškozené pixely nastaveny na hodnotu jedna, jež odpovídá bílé barvě, nebo nula, jež odpovídá barvě černé. Výše uvedené má za následek pojmenování tohoto šumu – Sůl a Pepř. [8]


Parametrem tohoto šumu je hustota – d (z anglického density), jež určuje, jaké procento z celkového počtu pixelů bude nahrazeno zmíněným poškozením. Například jestliže bude $d = 0,1$; tak 10 % pixelů bude defektních. [8]

Pro představu fungování si představme matici náhodných hodnot o rozměrech 4×3 . Náhodné hodnoty nabývají hodnot od 0 do 10. Tuto matici aplikujeme na obrazovou matici. Pozice s hodnotou nula budou nahrazeny v obrazu nulou a pozice s hodnotou deset jsou nahrazeny maximální hodnotou jasové úrovně tedy 255. Následující rovnice 7.2 je demonstrací této úvahy.


$$\begin{pmatrix} 232 & 105 & 174 \\ 224 & 85 & 153 \\ 214 & 110 & 179 \\ 62 & 128 & 69 \end{pmatrix} + \begin{pmatrix} 5 & 3 & 10 \\ 0 & 2 & 5 \\ 10 & 4 & 0 \\ 1 & 10 & 7 \end{pmatrix} = \begin{pmatrix} 232 & 105 & 255 \\ 0 & 85 & 153 \\ 255 & 110 & 0 \\ 62 & 255 & 69 \end{pmatrix} \quad (7.2)$$

Tento šum obecně poškozuje digitální obraz poruchou pixelových prvků v senzorech kamery, chybami v procesu digitalizace, nedostatečným místem v paměti a mnoha dalšími. Salt and Pepper

je nejlépe odstranitelným pomocí mediánového filtru. Obrázky 7.4 a 7.5 znázorňují různé stupně zašumění pomocí šumu Salt and Pepper. Obrázek 7.4 byl získán z CT a 7.4 z MRI.



Obrázek 7.4: Aplikace šumu Salt and Pepper na medicínský snímek cév břišní dutiny získaný pomocí CT. Vlevo nativní snímek, střed zašuměn při parametru $d = 0,05$; vpravo $d = 0,15$. Zdroj vlastní.



Obrázek 7.5: Aplikace šumu Salt and Pepper na medicínský snímek cév dolních končetin získaný pomocí MRI. Vlevo nativní snímek, střed zašuměn při parametru $d = 0,05$; vpravo $d = 0,15$. Zdroj vlastní.

7.3 Speckle šum

Šum Speckle je klasifikován jakožto multiplikativní typ. Tento šum má za následek obtížné rozpoznávání detailních informací na konečném snímku, protože způsobuje vytváření tmavých a světlých míst, jež může v konečném důsledku vést k nesprávnému vyhodnocení a chybné diagnóze. Následná rovnice je matematickým popisem tohoto šumu. [22]

$$A = I + m \cdot I \quad (7.3)$$

Kde:

A : je výstupní snímek


I : je vstupní snímek

m : je šum

Šum má rovnoměrné rozdělení se středem v bodě nula. Při $m = 0$ je snímek zcela bez jakéhokoliv přidaného šumu, naopak při hodnotě $m = 1$ bude snímek zcela zašuměn. Obrázky 7.6 a 7.7 jsou příklady aplikace šumu. Obrázek 7.6 byl získán z CT a obrázek 7.7 z MRI.



Obrázek 7.6: Aplikace šumu Speckle na medicínský snímek cév břišní dutiny získaný pomocí CT. Vlevo nativní snímek, střed zašuměn parametrem $\sigma^2 = 0,1$; vpravo $\sigma^2 = 0,25$. Zdroj vlastní.



Obrázek 7.7: Aplikace šumu Speckle na medicínský snímek cév dolních končetin získaný pomocí MRI. Vlevo nativní snímek, střed zašuměn parametrem $\sigma^2 = 0,1$; vpravo $\sigma^2 = 0,25$. Zdroj vlastní.

7.4 Ricianův šum

Majorita snímků z magnetické rezonance (MRI) je nativně degradována Riciánovým šumem, jež vzniká z Gaussova šumu tím, že reálná i imaginární signálová část je poškozena nekorelovanou nulovou střední hodnotou. Velikost signálu lze vyjádřit následovně:

$$M = \sqrt{(A + n_1)^2 + n_2^2}, \quad (7.4)$$

Kde:

M : je konečný snímek

I : je původní obraz

n_1 : je nekorelovaná proměnná Gaussova šumu

n_2 : je nekorelovaná proměnná Gaussova šumu

Proměnné n_1 a n_2 mají nulovou střední hodnotou a ekvivalentní rozptyl. Distribuce pravděpodobnosti pro měřenou intenzitu pixelů u Ricianova šumu je dána matematickým předpisem [24, 25]:

$$p_M(M) = \frac{M}{\sigma^2} e^{-\frac{M^2 + A^2}{2\sigma^2}} I_0\left(\frac{A \cdot M}{\sigma^2}\right) \quad (7.5)$$

Kde:

M : je měřená intenzita pixelů

A : je intenzita pixelů za nepřítomnosti šumu


I_0 : je modifikovaný nultý řád Besselovy funkce prvního druhu

σ : je směrodatná odchylka Gaussova šumu v reálném a imaginárním obraze


Obrázek 7.10 je grafem Ricianovy distribuce. Z grafu je možné vyčíst, že při nízké hodnotě SNR, tj. odstupu signálu od šumu, ($\frac{A}{\sigma} \leq 1$) se tato distribuce nepodobá Gaussově, ale při $\text{SNR} = 3$ už začíná být podobnost velmi viditelná.



Obrázek 7.8: Aplikace Riciánova šumu na medicínský snímek cév břišní dutiny získaný pomocí CT. Vlevo nativní snímek, střed zašuměn parametrem $s = 15$, vpravo pak při $s = 30$. Zdroj vlastní.



Obrázek 7.9: Aplikace Riciánova šumu na medicínský snímek cév dolních končetin získaný pomocí MRI. Vlevo nativní snímek, střed zašuměn parametrem $s = 15$, vpravo pak při $s = 30$. Zdroj vlastní.



Obrázek 7.10: Ricianova distribuce pro různé hodnoty SNR a $\frac{A}{\sigma}$. [25]


Kapitola 8

Použité segmentační metody

Tato kapitola se zabývá použitými segmentačními metodami, konkrétně metodou Otsu a Fuzzy C-meansy. Jde pouze o krátké shrnutí a více o fungování těchto metod lze najít v kapitole 5.

8.1 Metoda Otsu

Otsu metoda je modifikovaná metoda prahování, která je řazena mezi statistické metody z důvodu pracování na základě statistického parametru rozptylu, jež je ukazatelem variability rozdělení, konkrétně rozdělení pixelů v obraze. Tato metoda využívá klasifikaci pixelů do jednotlivých segmentačních regionů, a tudíž je jedna z metod multiregionální segmentace, kdy platí že při definování počtu tříd n vznikne $n + 1$ regionů. Otsu metoda pracuje na bázi prahování histogramů (viz obrázek 8.1), čímž se definuje počet oblastí. Hledá se taková segmentační třída, jejíž rozptyl bude co nejmenší, což bude značit optimálně zvolený práh. [10]



Obrázek 8.1: Ukázka segmentace pomocí metody Otsu. Vlevo nativní monochromatický snímek, ve středu histogram se znázorněnými prahy a vpravo zpracovaný snímek, tj segmentovaný. Zdroj vlastní

8.2 Metoda Fuzzy C-means


Metoda fuzzy c-means používá, jak už je z názvu zřejmé, fuzzy logiku, kterážto je známá gradientem příslušnosti, což je možnost nabývání hodnoty mezi 0 a 1 (viz obrázek 8.2). Metoda je založena na hledání těžišť shluků pomocí iterativního opravování pozic. Tato metoda je flexibilnější z důvodu možnosti částečné náležitosti shluků. Následující kroky jsou základním algoritmem metody

Krok 1 : Inicializace těžiště shluku c_i , nechť $t = 0$.

Krok 2 : Inicializace funkce fuzzy členství dle rovnice (5.28).

Krok 3 : Nechť $t = t + 1$, vypočti nové těžiště shluku c_i pomocí rovnice (5.29).

Krok 4 : Opakuj krok 2 a 3 až do konvergence.



Obrázek 8.2: Ukázka segmentace pomocí metody Fuzzy C-means. Vlevo nahoře nativní monochromatický snímek, vpravo nahoře zpracovaný snímek, tj segmentovaný, a dole mapa funkcí příslušnosti. Zdroj vlastní

Kapitola 9

Vyhodnocení kvality segmentace

K vyhodnocení kvality segmentace jsou využívány tzv. evaluační parametry. Evaluačními parametry jsou index strukturální podobnosti (SSIM – Structural Similiarity Index), korelační koeficient, Dice koeficient, střední kvadratická chyba (MSE – Mean Square Error), kalcifikační skóre, rozdíl kalcifikačního skóre mezi segmentačními regiony v původním a následně degradovaným snímkem a také rozdíl ploch segmentací, též mezi původním a degradovaným.

9.1 Index strukturální podobnosti (SSIM)

Tento index vyjadřuje podobnost obrazu x a y . Výsledné hodnoty indexu: $SSIM \in [-1, 1]$. Hodnota 1 je ukazatelem absolutní totožnosti obrazů. Na základě porovnání výsledků jasu, kontrastu a struktury mezi obrazy, jsou dány komponenty vzorce. Předpis indexu je následovný [12, 26]:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (9.1)$$

S doplněním:

$$C_i = (k, L)^2 \quad (9.2)$$

Kde:

L : je dynamický rozsah pixelů

k : je konstanta

x : je první obraz

y : je druhý obraz

μ : je vážený průměr obrazů

σ : je kovariance obrazů

9.2 Dice koeficient

Dice koeficient, jinak též známý pod jménem Sørensen–Dice je statistika užívána k měření podobnosti dvou různých vzorků. Tento koeficient může být použit jako metrika průniků dvou fuzzy setů. V porovnání s Euklidovskou vzdáleností si Sørensenova vzdálenost zachovává citlivost ve více heterogenních souborech dat a dává menší váhu odlehlým hodnotám. Dice koeficient je používán v obrazové segmentaci, zejména pro porovnání výstupu algoritmu s referenčními maskami. [27]:

$$DSC = \frac{2|X \cap Y|}{|X| + |Y|} \quad (9.3)$$

Kde:

X : je počet elementů v prvním setu dat

Y : je počet elementů v druhém setu dat

9.3 Střední kvadratická chyba (MSE)

Tento parametr vyjadřuje úroveň střední kvadratické chyby mezi nativním a zašuměným obrazem. Náročnost na výpočetní výkon je poměrně nízká, jelikož je metoda založena na srovnávání obrazů na pixelové úrovni. MSE je dáno vztahem [12, 28]:

$$MSE = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} [f(x, y) - \hat{f}(x, y)]^2 \quad (9.4)$$

Kde:

M : je velikost obrazu horizontálně

N : je velikost obrazu vertikálně

$f(x, y)$: je hodnota pixelu na souřadnicích (x, y)

9.4 Kalcifikační skóre

Procedura segmentace dovoluje extrakci jednotlivých komponentů cévního systému. Na základě faktu, že kalcifikace se při segmentaci zobrazí jinak než samotné cévní řečiště, můžeme zavést výpočet kalcifikačního skóre. Toto skóre je objektivním hodnocením úrovně kalcifikace. Výpočet je velmi jednoduchý, jelikož se jedná o podíl oblasti cévy a kalcifikace, kterýžto je dále přenásoben stem pro získání procentuální hodnoty. Vzorec pro výpočet je následovný [29]:

$$CS = \frac{A_{bv}}{A_c} * 100[\%] \quad (9.5)$$

Kde:

A_{bv} : je oblast cévního řečiště

A_c : je oblast kalcifikace

9.5 Korelační koeficient

Tento parametr představuje lineární korelaci dvou proměnných. Výsledek je dán poměrem kovariance proměnných vynásobených jejich směrodatnými odchylkami. Míra korelace je vyjádřena korelačním koeficientem, označován r . Kvadrát korelačního koeficientu, označován r^2 , je nazýván koeficient determinace. Výsledné hodnoty jichž parametry nabývají: $r \in [-1, 1]$ a $r^2 \in [0, 1]$. Pearsonův korelační koeficient je dán vztahem [12, 30]:

$$PCC = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (9.6)$$

Kde:

\bar{x}, \bar{y} : jsou individuální aritmetické průměry ze souborů X a Y

x_i, y_i : jsou individuální párované vzorky ze souborů X a Y

n : je celkový počet párů

Čím podobnější jsou si veličiny X a Y , tím více se absolutní hodnota koeficientu blíží jedné. V základu se jedná o bezrozměrnou veličinu, ale lze získat procentuální hodnotu při vynásobení stem.

9.6 Rozdíl kalcifikačního skóre

Tato metrika byla zvolena, aby bylo možné objektivně říci, jakou mírou šum ovlivnil výsledek segmentační metody. Metrika je založena na pouhém rozdílu KS. Konkrétně rozdílu KS degradovaného snímku a KS původního nezašuměného, jež je brán jakožto reference. Metrika je dána vztahem:

$$KS_{dif} = KS_{deg} - KS_{ref} \quad (9.7)$$

Kde:

KS_{deg} : je KS vypočtené z degradovaného snímku

KS_{ref} : je KS vypočtené z původního snímku

9.7 Rozdíl ploch segmentací

Tato metrika je založena na rozdílu plochy extrahovaných regionů segmentace degradovaného snímku a snímku původního, tj. referenčního. Tento údaj vypovídá o změně plochy segmentačních regionů, což je vázáno mírou degradace snímku a také typem šumu. Metrika je dána vztahem:

$$S_{dif} = S_{deg} - S_{ref} \quad (9.8)$$

Kde:

S_{deg} : je plocha vypočtená z degradovaného snímku

S_{ref} : je plocha vypočtená z původního snímku

Kapitola 10

Zpracování grafického uživatelského rozhraní


Uživatelské rozhraní bylo zpracováno s ohledem na vstupní datasety původem z CT a MRI. Tyto obrazové datasety byly převedeny na monochromatický obraz. Na tyto převedené obrazy je možné aplikovat čtyři vybrané šumy, tj. Gaussův šum, šum Speckle, šum Salt & Pepper a Rician šum. Z tohoto zpracování dostaneme volitelnou dávku snímků. Snímky v dávce jsou lineárně iterativně zašuměny, tím je myšleno, že po zadání parametru minimální a maximální hodnoty je tento interval lineárně rozdělen dle zadané hodnoty konečného počtu snímků.

Následně je tato množina degradovaných snímků dávkově segmentována pomocí metody Otsu víceúrovňového prahování a metody Fuzzy C-means. Poté se uživatelsky vyberou regiony cévy a případně přítomné patologie, tj. kalcifikace, k extrakci. Následně proběhne evaluace segmentace, jejíž hodnoty jsou vyneseny do grafů. Výsledné proměnné a grafické výstupy je možné exportovat do složky reportu.

10.1 Grafické uživatelské prostředí (GUI) – uživatelská část

Design GUI byl navržen jako uživatelsky přívětivý zohledňující posloupnost prováděných kroků a operací. Obrázek 10.1 je vývojovým diagramem představující tok práce uživatele v GUI.

Obrázek 10.2 zobrazuje první ze tří záložek vytvořeného grafického uživatelského prostředí, to jest dávkovou aplikaci šumu. Dalšími záložkami jsou dávková segmentace, která je na obrázku 10.3 a evaluace segmentace na obrázku 10.4.




Obrázek 10.1: Vývojový diagram pro práci uživatele s GUI. Zdroj vlastní.

10.1.1 Dávková aplikace šumu

Obrázek 10.2 je tím prvním, co uživatel po spuštění uvidí. Aplikací se pohybuje pomocí záložek. V první záložce, která se nazývá *Dávková aplikace šumu*, se nejprve zvolí možnosti importu a předzpracování – komponenta B. Nejprve se načte snímek z datasetu, následně proběhne extrakce a dále je i možnost obnovení snímku.

Uživatel také může využít export do workspace, případně uložit – komponenta C. Ve spodní části obrazovky je parametrizace, která se ovládá ručně. V této části vidíme čtyři záložky – komponenta D, které jsou pojmenovány podle jednotlivých šumů, které je možné touto aplikací zpracovávat.

V každé záložce si uživatel stanoví parametr – komponenta E. Dále si uživatel určuje i počet snímků, které chce po aplikaci, aby vykreslila – komponenta F




Obrázek 10.2: Záložka dávkové aplikace šumu s označenými komponentami. Zdroj vlastní.

10.1.2 Dávková segmentace


Dávková segmentace je druhou záložkou, kterou uživatel použije v průběhu simulace a je znázorněna na obrázku 10.3. Záložka obsahuje možnost importu, a to ze souboru – komponenta A. Dále si uživatel volí možnost exportu stejně jako v záložce *Dávková aplikace šumu* – komponenta B. V této obrazovce je také možnost výběru segmentace, kde si uživatel zvolí buď metodu segmentace Otsu anebo Fuzzy C-means – komponenta C. Dále je možno uživatelsky zaškrtnout, zda kalcifikace na snímku je přítomna, či nikoliv – komponenta D, pokud uživatel má potřebu s tímto parametrem pracovat.

Dále si může uživatel stanovit, na kolik oblastí se daný snímek rozdělí, tedy stanovuje počet regionů – komponenta E. Ve stejné záložce v prostřední části obrazovky – komponenta H, se pak vykresluje nasegmentovaný snímek pro výběr regionů v komponentě G.

Komponenta F – umožňuje přepínat mezi možnostmi výběru regionů pro cévy a kalcifikaci. Na téže obrazovce je komponenta J a K. V komponentě J probíhá zobrazení regionu cévy a v komponentě K pak regionu kalcifikace.



Obrázek 10.3: Záložka dávkové segmentace s označenými komponentami. Zdroj vlastní.



Obrázek 10.4: Záložka evaluace segmentace s označenými komponentami. Zdroj vlastní.

10.1.3 Evaluace segmentace


Evaluace segmentace je třetí a poslední záložkou simulační aplikace a je znázorněna na obrázku 10.4. Zde jsou možnosti vykreslení, a to do exportu, stejně jako v záložce 1 a 2 a také možnost vytvoření reportu – komponenta B. Důležité na této obrazovce pro uživatele je komponenta C, která umožňuje vybrat postupně všechny zde uvedené evaluační parametry a graficky je zobrazit.

10.2 Grafické uživatelské prostředí (GUI) – algoritmická část

Grafické uživatelské rozhraní bylo programováno v software MATLAB. Po nastudování problematiky bylo přistoupeno k programovému zpracování v prostředí MATLAB. MATLAB je programovací a numerická výpočetní platforma, která je využívána k analýze dat, vývoji algoritmů a vytváření modelů.

V prostředí MATLAB byla použita komponenta *app designer*, ve které, jak už jméno napovídá, je možné graficky nadesignovat aplikaci, což automaticky vytváří hlavní kostru aplikace. Dále byly vytvořeny externí volané funkce, jimiž jsou například funkce dávkové aplikace jednotlivých šumů nezávisle na sobě, nebo jednotlivé metody segmentace, jež v sobě nesly i algoritmy pro externí zobrazení. Externím zobrazením se rozumí zobrazení mimo okno aplikace.

Vývojový diagram zpracování vstupních snímků vytvořenou aplikací znázorňuje obrázek 10.5.



Obrázek 10.5: Způsob práce vytvořeného GUI. Zdroj vlastní.


10.2.1 Dávková aplikace šumu

Zpracovaná aplikace GUI má pomoci při vyhodnocování a zobrazování vstupních datasetů pomocí zašumění až čtyřmi vstupními šumy:

- Gaussův šum , který umožňuje rovnoměrné ovlivnění všech pixelů dopsat vzorce z prezentace
- Speckle šum, který umožňuje ovlivnění struktury
- Salt & Pepper šum , který ostře narušuje obraz
- Rician šum, jež se majoritně vyskytuje na snímcích z MRI

Více informací o výše zmíněných šumech, tj. např. vznik nebo matematický popis, lze nalézt v teoretické části této práce, konkrétně v kapitole 7.

Pro jednotlivé šumy probíhá algoritmus způsobem, jež je znázorněn na obrázku 10.6.




Obrázek 10.6: Algoritmus dávkové degradace snímků šumem. Zdroj vlastní.

Postupné kroky zpracování:

- Načtení snímku: V tomto kroku je vybrán a načten do aplikace snímek ze zvoleného adresáře. Po načtení je kontrolován formát, čímž je myšlena kontrola dimenzí. Pakliže je snímek v RGB formátu, provede se převod na monochromatický snímek.
- Extrakce ROI: V tomto kroku je nutno snímek oříznout od popisků, jež jsou automaticky generovány akvizičními systémy. Toto je důležité z důvodu, že popisky se po převodu do monochromatického obrazu jeví jako převážně bílé, což by mělo za následek špatnou evaluaci. Tímto je získáno ROI, jinak také oblast zájmu.
- Typ šumu: V tomto kroku je volen šumový generátor, a to jeden ze čtyř možných. Tyto šumy jsou uvedeny výše.
- Intenzita šumu: V tomto kroku je volena intenzita šumu, což je parametr, jež je modifikátorem, který figuruje v matematickém popisu.
- Počet výstupních snímků dávky: V tomto kroku je volen počet výstupních snímků dávky. Tento počet znamená, na kolik částí se interval intenzity šumu včetně své maximální a minimální hodnoty rozdělí.

10.2.2 Dávková segmentace

Na zpracované snímky následně použijeme segmentační metody Otsu nebo Fuzzy C-means. Otsu metoda pracuje s rozptylem a na základě prahování histogramu. Metoda Fuzzy C-means je založen na fuzzy logice, kdy je rozhodováno o míře příslušnosti pixelu do regionů. Detailní popis lze najít v kapitole 5.



Obrázek 10.7: Algoritmus dávkové segmentace. Zdroj vlastní.

Postupné kroky zpracování:


- Vstupní snímek po dávkové aplikaci šumu: Jedná se o výstupní snímek zpracovaný v předchozím kroku, tj. dávková aplikace šumu.
- Výběr metody segmentace: V tomto kroku je voleno ze dvou segmentačních metod, a to Otsu a Fuzzy C-means.
- Potvrzení přítomnosti kalcifikace: V tomto kroku je voleno, zdali je patologie, konkrétně kalcifikace přítomna, či nikoliv. Tímto rozhodnutím je ovlivněn následný výstup extrakce.
- Výběr počtu regionů: V tomto kroku je volen počet chtěných segmentačních regionů, tj. oblastí se stejnými vlastnostmi.
- Výběr regionů k extrakci: V tomto kroku jsou voleny regiony, jež zastupují oblast zájmu, tj. cévy nebo kalcifikace. Tyto regiony jsou poté extrahovány, zbinarizovány a zobrazeny.

10.2.3 Evaluace segmentace

V konečné části GUI je možno vybrat ze sedmi evaluačních kritérií a graficky zobrazit výsledek. Bližší informace o parametrech lze najít v kapitole 9. Kritéria, které je možné zobrazit jsou následující:

1. *SSIM*: Index strukturální podobnosti je metrika vyjadřující podobnost dvou obrazů.
2. *MSE*: Střední kvadratická chyba je veličina, která odráží stupeň střední kvadratické chyby mezi nativním a šumem znehodnoceným snímkem.
3. *Dice*: Dice koeficient je statistika užívána k měření podobnosti dvou různých vzorků.
4. *Korelační koeficient* představuje lineární korelaci dvou proměnných. Výsledek je dán poměrem kovariance proměnných vynásobených jejich směrodatnými odchylkami.
5. *Kalcifikační skóre* je objektivním hodnocením úrovně kalcifikace.

6. *Rozdíl kalciфикаčního skóre* je objektivním ukazatelem míry ovlivnění segmentace šumem.
7. *Rozdíl ploch segmentací* vypovídá o změně plochy segmentačních regionů, což je vázáno mírou degradace snímku a také typem šumu.



Obrázek 10.8: Volba zobrazení evaluačních parametrů. Zdroj vlastní.

Kapitola 11

Výstupy a výsledky z GUI

Výstupy z grafického uživatelského prostředí lze rozdělit na tři skupiny, kdy první dva výstupy jsou obrazové, a třetí je datový. Tyto výstupy lze pomocí tlačítka *Vytvořit report* uložit do automaticky generované složky, jejíž název je souborem parametrů, jež byly využity v průběhu simulace.


11.1 První skupina – obrazová

První skupina je složka externích výstupních snímků, tj. snímků zobrazujících se mimo okno aplikace, což jsou dávky zašuměných snímků, segmentací a extrakcí. Obsah této složky a jednotlivé výstupy jsou popsány v tabulce 11.1, která také obsahuje odkazy na jednotlivé výstupní obrázky.


Tabulka 11.1: Přehledová tabulka obsahu složky *Figs*. Pevně daná jména jednotlivých uložených grafických výstupů a co zastupují. Zdroj vlastní.

Číslo	Jméno obrázku	Význam obrázku	Odkazy CT MRI
Záložka č.1 – Dávková aplikace šumu			
1	a_BatchNoise	Obrázek dávkového šumu	Obrázek 11.1 11.8
Záložka č.2 – Dávková segmentace - Otsu			
2	b_Otsu	Obrázek dávkové segmentace	Obrázek 11.2 11.9
3	b_Otsu_RegVessel	Obrázek extrahovaných regionů cévy	Obrázek 11.3 11.10
4	b_Otsu_RegKalcif	Obrázek extrahovaných regionů kalcifikace	Obrázek 11.4
Záložka č.2 – Dávková segmentace - Fuzzy C-means			
5	c_FCM	Obrázek dávkové segmentace	Obrázek 11.5 11.11
6	c_FCM_RegVessel	Obrázek extrahovaných regionů cévy	Obrázek 11.6 11.12
7	c_FCM_RegKalcif	Obrázek extrahovaných regionů kalcifikace	Obrázek 11.7


11.1.1 Výstupy snímků s patologií – CT




Obrázek 11.1: Výstup z dávkové aplikace šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.2: Výstup z dávkové segmetace pomocí Otsu metody. Zvolený počet regionů je 5. Zdroj vlastní.




Obrázek 11.3: Výstup z dávkové extrakce regionů cévy – Otsu. Vybrané regiony k extrakci byly 3, 4, 5. Zdroj vlastní.




Obrázek 11.4: Výstup z dávkové extrakce regionů kalcifikace – Otsu. Vznik tohoto snímku značí, že byla zvolena možnost přítomnost kalcifikace. Vybrané regiony k extrakci byly 4, 5 Zdroj vlastní.



Obrázek 11.5: Výstup z dávkové segmetace pomocí Fuzzy C-means metody. Zvolený počet regionů je 5. Zdroj vlastní.



Obrázek 11.6: Výstup z dávkové extrakce regionů cévy – Fuzzy C-means. Vybrané regiony k extrakci byly 3, 4, 5. Zdroj vlastní.




Obrázek 11.7: Výstup z dávkové extrakce regionů kalcifikace – Fuzzy C-means. Vznik tohoto snímku značí, že byla zvolena možnost přítomnost kalcifikace. Vybrané regiony k extrakci byly 4,5. Zdroj vlastní.

Obrázky dávkových výstupů výše jsou přímým externím výstupem aplikace. Obrázek 11.1 je výstupem dávkové aplikace šumu. V tomto případě byl použit šum Salt & Pepper s parametrem intenzity, v tomto případě denzitou $d = 0 - 0,2$; a dávkou velikosti 9.


Poté následuje krok dávkové segmentace první vybranou metodou. Výstupem tohoto kroku je obrázek 11.2, k jehož vytvoření byla použita segmentační metoda Otsu s nastavením počtu regionů na 5. Další krok, což je extrakce regionů, produkuje dávkovou extrakci segmentačních regionů. Výstupem tohoto kroku je obrázek 11.3 a obrázek 11.4. Obrázek 11.3 představuje výstup dávkové extrakce segmentačních regionů oblasti cévy a obrázek 11.4 oblasti kalcifikace.

Následně je opakován předchozí blok dávkové segmentace, ale pomocí metody Fuzzy C-mean, jehož výstupem je obrázek 11.5. To samé je provedeno pro extrakci regionů, což produkuje obrázek 11.6 pro extrakci regionů oblasti cévy, a obrázek 11.7 pro regiony oblasti kalcifikace.


11.1.2 Výstupy snímků bez patologie – MRI




Obrázek 11.8: Výstup z dávkové aplikace šumu. Použitý šum je Rician s parametrem $s = 0 - 36$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.9: Výstup z dávkové segmetace pomocí Otsu metody. Zvolený počet regionů je 7. Zdroj vlastní.



Obrázek 11.10: Výstup z dávkové extrakce regionů cévy – Otsu. Vybrané regiony k extrakci byly 5, 6, 7. Zdroj vlastní.



Obrázek 11.11: Výstup z dávkové segmetace pomocí Fuzzy C-means metody. Zvolený počet regionů je 7. Zdroj vlastní.



Obrázek 11.12: Výstup z dávkové extrakce regionů cévy – Fuzzy C-means. Vybrané regiony k extrakci byly 5, 6, 7. Zdroj vlastní.

Obrázky dávkových výstupů výše jsou přímým externím výstupem aplikace. Obrázek 11.8 je výstupem dávkové aplikace šumu. V tomto případě byl použit šum Rician s parametrem intenzity $s = 0 - 36$, a dávkou velikosti 9.

Poté následuje krok dávkové segmentace první vybranou metodou. Výstupem tohoto kroku je obrázek 11.9, k jehož vytvoření byla použita segmentační metoda Otsu s nastavením počtu regionů na 7. Další krok, což je extrakce regionů, produkuje dávkovou extrakci segmentačních regionů. Výstupem tohoto kroku je obrázek 11.10, jenž představuje výstup dávkové extrakce segmentačních regionů oblasti cévy.

Následně je opakován předchozí blok dávkové segmentace, ale pomocí metody fuzzy c-mean, jehož výstupem je obrázek 11.11. To samé je provedeno pro extrakci regionů, což produkuje obrázek 11.12 pro extrakci regionů oblasti cévy.

11.2 Druhá skupina – obrazová

Druhá skupina je množina interního zobrazování snímků, které probíhá uvnitř aplikace v elementech vykreslujících grafiku. V tabulce 11.2 je uveden obsah této skupiny. Tabulka rovněž obsahuje odkazy na každý obrázek grafu příslušného evaluačního parametru. Každý graf evaluačního parametru, obrázky 11.13 až 11.19, mimo 11.17 a 11.18, obsahuje křivky vypočtených hodnot pro region cévy a kalcifikace při metodě Otsu nebo fuzzy c-means, mimo parametr kalcifikačního skóre a rozdíl kalcifikačního skóre. Tyto dva parametry, obrázek 11.17 a 11.18, jsou počítány z oblastí cévy a kalcifikace, proto je jen jeden soubor hodnot pro každou z metod.


Tabulka 11.2: Přehledová tabulka obsahu složky *Eval*. Pevně daná jména jednotlivých uložených grafických výstupů a co zastupují. Zdroj vlastní.

Číslo	Jméno obr.	Význam obrázku	Odkazy CT MRI
1	SSIM	Graf trendu vývoje SSIM v závislosti na šumu	Obr. 11.13 11.20
2	MSE	Graf trendu vývoje MSE v závislosti na šumu	Obr. 11.14 11.21
3	Dice	Graf trendu vývoje Dice v závislosti na šumu	Obr. 11.15 11.22
4	Corr	Graf trendu vývoje Corr v závislosti na šumu	Obr. 11.16 11.23
5	KS	Graf trendu vývoje KS v závislosti na šumu	Obr. 11.17
6	KS_dif	Graf trendu vývoje rozdílu KS v závislosti na šumu	Obr. 11.18
7	KS_Area	Graf trendu vývoje rozdílu plochy v závislosti na šumu	Obr. 11.19 11.24


V grafech 11.13 až 11.19, mimo 11.17 a 11.18, lze vidět že snímek, na něhož byl aplikován generátor šumu typu Salt & Pepper s parametrem intenzity, tj. denzity $d = 0 - 0,2$, vykazoval konzistentnější výsledky evaluačních parametrů při použití metody víceúrovňového prahování, tj. metody Otsu, kdy parametry měly jasný trend postupného, až úrovňového, sestupu nebo růstu, na základě parametrového intervalu; a naopak při použití metody Fuzzy C-means lze vidět skokové snížení kvality segmentace při použití šumové intenzity, tj. parametru denzity $d = 0,1$. V grafu 11.17, lze pozorovat jasný markantní hodnotový nárůst vypočteného kalcifikačního skóre, jež je zapříčiněno použitým šumem Salt & Pepper, kterýžto vytváří v obraze ryze černé a ryze bílé artefakty. Bílé artefakty jsou poté segmentovány do stejné třídy jakožto kalcifikace. Graf 11.18 je pouze ukazatelem absolutního přírůstku.

V grafech 11.20 až 11.23 lze vidět vývoje hodnot vypočtených evaluačních parametrů v závislosti na intenzitě použitého šumu, v tomto případě šum Rician s parametrem intenzity $s = 0 - 36$, na snímku z MRI. Vypočtené parametry jsou pro obě segmentační metody víceméně stejné až do hodnoty č.8, kdy je možné pozorovat jejich rozcházení, konkrétně metoda Fuzzy C-means od 8. hodnoty nabývá horších hodnot. Graf 11.24 zobrazuje plochu extrahovaných regionů zájmu, tedy cévy. Hodnota č.9 na tomto grafu značí skokové zvýšení plochy při intenzitě $s = 36$ oproti předchozí intenzitě $s = 31,5$.


11.2.1 Výstupy snímků s patologií – CT




Obrázek 11.13: Snímek grafu trendu vývoje indexu strukturální podobnosti v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.14: Snímek grafu trendu vývoje střední kvadratické chyby v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.15: Snímek grafu trendu vývoje Dice koeficientu v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.16: Snímek grafu trendu vývoje korelačního koeficientu v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.



Obrázek 11.17: Snímek grafu trendu vývoje kalcifikačního skóre v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.18: Snímek grafu trendu vývoje rozdílu kalcifikačního skóre v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem denzity $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.19: Snímek grafu trendu vývoje rozdílu plochy extrahovaných segmentů v závislosti na šumu. Použitý šum je Salt & Pepper s parametrem $d = 0 - 0,2$; a dávka je 9 snímků. Zdroj vlastní.


11.2.2 Výstupy snímků bez patologií – MRI




Obrázek 11.20: Snímek grafu trendu vývoje indexu strukturální podobnosti v závislosti na šumu. Použitý šum je Rician s parametrem $s = 0 - 36$; a dávka je 9 snímků. Zdroj vlastní.




Obrázek 11.21: Snímek grafu trendu vývoje střední kvadratické chyby v závislosti na šumu. Použitý šum je Rician s parametrem $s = 0 - 36$; a dávka je 9 snímků. Zdroj vlastní.



Obrázek 11.22: Snímek grafu trendu vývoje Dice koeficientu v závislosti na šumu. Použitý šum je Rician s parametrem $s = 0 - 36$; a dávka je 9 snímků. Zdroj vlastní.



Obrázek 11.23: Snímek grafu trendu vývoje korelačního koeficientu v závislosti na šumu. Použitý šum je Rician s parametrem $s = 0 - 36$; a dávka je 9 snímků. Zdroj vlastní.



Obrázek 11.24: Snímek grafu trendu vývoje rozdílu plochy extrahovaných segmentů v závislosti na šumu. Použitý šum je Rician s parametrem $s = 0 - 36$; a dávka je 9 snímků. Zdroj vlastní.

11.3 Třetí skupina – datová

Třetí a poslední skupina je množina výsledných proměnných, jež byly postupně vypočítány při běhu simulační aplikace, kterou je následně možné archivovat pro další analýzu. Tabulka 11.3 ukazuje jaké proměnné jsou ukládány do souboru *Report.mat*. Při prostém načtení tohoto souboru do prostředí MATLAB bude workspace vypadat tak jako na obrázku 11.25.

Tabulka 11.3: Obsah výstupní datové proměnné. Množina výsledných proměnných, jež byly postupně vypočítány při běhu simulační aplikace. Zdroj vlastní.


Číslo	Jméno proměnné	Význam proměnné
Záložka č.1 – Dávková aplikace šumu		
1	Native	Původní snímek
2	ROI	Snímek po ořezu
3	NoiseBatch	Matice snímků s dávkovým šumem
4	prms	Parametry generace šumu
5	BatchNum	Počet snímků v dávce
Záložka č.2 – Dávková segmentace		
6	Label	Matice segmentačních masek
7	Vessel	Vybrané regiony (binární snímek) cévy
8	Kalcif	Vybrané regiony (binární snímek) kalcifikace
9	SelRegVes	Vybrané regiony (čísla) cévy
10	SelRegKal	Vybrané regiony (čísla) kalcifikace
11	RegNum	Počet zadáných segmentačních regionů
Záložka č.3 – Evaluace segmentace		
12	Eval_KS	Kalcifikační skóre
13	Eval_KS_RefDif	Kalcifikační skóre rozdíl
14	Eval_LV_Area	Rozdíl plochy extrahovaných segm. cévy
15	Eval_LK_Area	Rozdíl plochy extrahovaných segm. kalcifikace
16	LV_Corr	Korelační koeficient pro cévu
17	LK_Corr	Korelační koeficient pro kalcifikaci
18	LV_Dice	Sorensen-Dice koef. pro cévu
19	LK_Dice	Sorensen-Dice koef. pro kalcifikaci
20	LV_MSE	MSE pro cev
21	LK_MSE	MSE pro kalcifikaci
22	LV_SSIM	SSIM pro cev
23	LK_SSIM	SSIM pro kalcifikaci

A
B

Obrázek 11.25: Načtený soubor *Report.mat* ve workspace. A: Obsah souboru pro CT, tj. snímek s patologií; B: Obsah souboru pro MRI, tj. snímek bez patologie. Zdroj vlastní.

11.4 Automaticky generovaný strom složek reportu

První úroveň je mateřský adresář. Jméno tohoto adresáře je složeno z jednotlivých parametrů, jež byly využity v průběhu aplikace. Toto je z důvodu unikátnosti reportové složky a snadného zjištění obsahu. Na druhé úrovni jsou složky *Eval*, *Figs* a *.mat* soubor výstupních hodnot a třetí úroveň je čistě grafická. Hierarchie stromu je znázorněna na obrázku 11.26.



Obrázek 11.26: Hierarchie stromu složky reportu. Žlutě složky, modře soubory a zeleně grafika.
Zdroj vlastní.

11.4.1 Mateřská složka

Mateřská složka je složka samotného reportu, jež je nadřazena všem. Předpis generace jména je znázorněn vztahem 11.1.

$$\text{name} = \text{a_b_c_de_f_}(g_h) \quad (11.1)$$

Kde:

name : je jméno složky

a : je název nativního snímku

b : je název zvoleného šumu

c : je definovaný počet snímků v dávce

d : je název parametru příslušného šumu

e : je hodnota parametru příslušného šumu


f : je definovaný počet segmentačních regionů

g : jsou čísla vybraných segm. regionů z masky pro extrakci cévy

h : jsou čísla vybraných segm. regionů z masky pro extrakci kalcifikace

11.5 Kroky práce s GUI

Obrázek 11.27 níže znázorňuje postup kroků průřezově v rámci celého simulačního grafického uživatelského prostředí. Obrázek byl zpracován pro názornou ukázkou práce s aplikací. Červené šipky znázorňují postup uživatelských kroků, fialové šipky jsou pouze informativního charakteru, tj. značí externí výstup, přičemž externím výstupem je myšleno mimo okno aplikace.



Obrázek 11.27: Zobrazení postupných kroků práce v GUI. Zdroj vlastní.

Kapitola 12

Závěr

Cílem této práce bylo vytvoření simulačního prostředí pro komparativní analýzu vybraných segmentačních algoritmů s cílem identifikace cévního systému včetně patologických nálezů. Dále poté dávkové kvantitativní testování robustnosti segmentačních algoritmů na reálných medicínských obrazech a extrakce a statistická analýza příznaků cévního systému a kalcifikačních oblastí.

Nejprve bylo potřeba nastudování aspektů zobrazovacích metod pro zobrazování cévního systému, a nastudování fyziologie a patologie cévního řečiště s orientací na cévní kalcifikace.

Pro zpracování grafického uživatelského prostředí byl použit software MATLAB, konkrétně komponenta návrhář aplikací, v angličtině *App Designer*. V této komponentě byla naprogramována převážná část aplikace. Zbylá část byla tvořena v prostředí MATLAB jako funkce, jež poté byly aplikací volány. Vstupní nativní testovací data byla vybrána z poskytnutých datasetů z CT a MRI. Části vytvořené aplikace jsou následovné:

- Záložka č.1, která umožňuje prvotní načtení vstupních nativních testovaných dat z výběrů z datasetů. Následně umožňuje vybrat druh šumu, který chceme na vstupní snímek aplikovat a jeho parametrizaci. Poté lze také navolit konečný počet snímků v dávce, čímž je myšleno na kolik částí se interval intenzity šumu včetně své maximální a minimální hodnoty rozdělí. Výstupem je dávka monochromatických šumem degradových snímků.
- Záložka č.2, která umožňuje zpracovat dávku snímků ze záložky č.1, a to vybranou metodou segmentace. Následně umožňuje rozhodnutí o přítomnosti kalcifikace a volbou regionů segmentace reprezentujících oblast zájmu.
- Záložka č.3, která umožňuje aplikací vypočtené hodnoty vynést do grafu. Konečný krok při práci s aplikací je zvolení vytvoření a uložení reportu. Reportem je myšleno uložení dat, která mohou sloužit k následné analýze. Formát výstupních dat je .png pro grafické soubory a .mat pro datovou strukturu ukládaných proměnných.

Tato práce může být využita jako studijní materiál pro studenty zabývajících se segmentací obrazu a dopadem různých intenzit šumů na segmentaci.

Součástí diplomové práce je zdrojový kód pro GUI a všechny volané funkce, a také provedené simulace.

Literatura

1. ČIHÁK, Radomír. *Anatomie*. 2., upr. a dopl. vyd. Praha: Grada, 2001-2004. ISBN isbn80-247-1132-x.
2. SILBERNAGL, Stefan; DESPOPOULOS, Agamemnon. *Atlas fyziologie člověka*. 6. vyd., zcela přeprac. a rozš., Vyd. 3. české. Praha: Grada, 2004. ISBN isbn80-247-0630-x.
3. TROJAN, Stanislav. *Lékařská fyziologie*. Vyd. 4., přeprac. a dopl. Praha: Grada, 2003. ISBN 80-247-0512-5.
4. SOUČEK, Miroslav; ŠPINAR, Jindřich; VORLÍČEK, Jiří. *Vnitřní lékařství*. Vyd. 1. Praha: Grada, 2011. ISBN 978-80-247-2110-1.
5. ČEŠKA, Richard; TESAŘ, Vladimír; DÍTĚ, Petr; ŠTULC, Tomáš. *Interna*. Vyd. 1. Praha: Triton, 2010. ISBN 978-80-7387-423-0.
6. BAXA, Jan. Význam zobrazovacích metod v prevenci kardiovaskulárních onemocnění. *Kardiologická revue: Interní medicína*. 2013, roč. 2013, č. 4, s. 224–229.
7. ŠPANĚL, Michal; BERAN, Vítězslav. *Obrazové segmentační techniky: Přehled existujících metod*. Brno, 2005. Dostupné také z: <http://www.fit.vutbr.cz/~spanel/segmentace/>. Studijní dokumentace. Vysoké učení technické v Brně.
8. DOUGHERTY, Geoff. *Digital image processing for medical applications*. 1st ed. Cambridge: Cambridge University Press, 2009. ISBN 978-0-521-86085-7.
9. STRAKA, Stanislav. *Segmentace obrazu* [online]. 2009 [cit. 2020-11-30]. Dostupné z: <https://is.muni.cz/th/tzp80/>. Diplomová práce. Masarykova univerzita.
10. VALOŠEK, Jan. *Automatizovaný software pro úpravu a analýzu medicínských snímků* [online]. Ostrava, 2015 [cit. 2020-11-15]. Dostupné z: <http://hdl.handle.net/10084/108897>. Bakalářská práce. Vysoká škola báňská - Technická univerzita Ostrava.
11. KHUSHBU; VATS, Isha. Otsu Image Segmentation Algorithm: A Review. *International Journal of Innovative Research in Computer and Communication Engineering* [online]. 2017, roč. 2017, č. 6 [cit. 2020-11-15]. ISSN 320-9801. Dostupné z DOI: 10.15680/IJIRCCE.2017.0506164.

12. HANČAROVÁ, Kristýna. *Moderní metody segmentace obrazu s využitím prvků umělé inteligence* [online]. Ostrava, 2020 [cit. 2020-12-04]. Dostupné z: <http://hdl.handle.net/10084/140446>. Diplomová práce. Vysoká škola báňská - Technická univerzita Ostrava.
13. HOROVÁ, Ivana; ZELINKA, Jiří. *Numerické metody*. 2., rozš. vyd. Brno: Masarykova univerzita v Brně, 2004. ISBN 8021033177,
14. BAJGAR, Aleš. *Segmentačních technik zpracování obrazu* [online]. Brno, 2011 [cit. 2020-12-01]. Dostupné z: <http://hdl.handle.net/11012/881>. Diplomová práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav telekomunikací.
15. HARIS, K.; EFSTRATIADIS, S.N.; MAGLAVERAS, N.; KATSAGGELOS, A.K. Hybrid image segmentation using watersheds and fast region merging. *IEEE Transactions on Image Processing* [online]. Roč. 7, č. 12, s. 1684–1699 [cit. 2020-12-01]. ISSN 10577149. Dostupné z DOI: 10.1109/83.730380.
16. BEUCHER, Serge; MEYER, Fernand. The Morphological Approach to Segmentation: The Watershed Transformation. In: 1993-01, sv. Vol. 34, s. 433–481. ISBN 9781315214610. Dostupné z DOI: 10.1201/9781482277234-12.
17. KUČERA, Michal. *Segmentovaná vlnková transformace obrazu* [online]. Brno, 2010 [cit. 2020-12-03]. Dostupné z: <http://hdl.handle.net/11012/5391>. Diplomová práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav telekomunikací.
18. HANÁK, Pavel. *Segmentace obrazů magnetické rezonance* [online]. Brno, 2010 [cit. 2020-12-03]. Dostupné z: <http://hdl.handle.net/11012/1735>. Bakalářská práce. Vysoké učení technické v Brně. Fakulta elektrotechniky a komunikačních technologií. Ústav radioelektroniky.
19. JI, L.; YAN, H. Loop-free snakes for image segmentation. In: *Proceedings 1999 International Conference on Image Processing (Cat. 99CH36348)* [online]. IEEE, 1999, s. 193–197 [cit. 2020-12-02]. ISBN 0-7803-5467-2. Dostupné z DOI: 10.1109/ICIP.1999.817099.
20. DHANACHANDRA, Nameirakpam; MANGLEM, Khumanthem; CHANU, Yambem Jina. Image Segmentation Using K -means Clustering Algorithm and Subtractive Clustering Algorithm. *Procedia Computer Science* [online]. 2015, roč. 54, s. 764–771 [cit. 2020-12-04]. ISSN 18770509. Dostupné z DOI: 10.1016/j.procs.2015.06.090.
21. ZHOU, Huiyu; SCHAEFER, Gerald; SHI, Chunmei. Fuzzy C-Means Techniques for Medical Image Segmentation. In: *Fuzzy Systems in Bioinformatics and Computational Biology* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009, s. 257–271 [cit. 2020-12-05]. ISBN 978-3-540-89967-9. Dostupné z DOI: 10.1007/978-3-540-89968-6_13.
22. HIREMATH, Prakash; AKKASALIGAR, Dr. Prema; BADIGER, Dr. Sharan. Removal of Gaussian Noise in Despeckling Medical Ultrasound Images. *International Journal of Computer Science and Applications*. 2012-07, roč. 1, s. 25–35.

23. BOYAT, Ajay; JOSHI, Brijendra. A Review Paper: Noise Models in Digital Image Processing. *Signal & Image Processing : An International Journal*. 2015-05, roč. 6. Dostupné z DOI: 10.5121/sipij.2015.6206.
24. AJA-FERNANDEZ, S.; ALBEROLA-LOPEZ, C.; WESTIN, C.-F. Noise and Signal Estimation in Magnitude MRI and Rician Distributed Images: A LMMSE Approach. *IEEE Transactions on Image Processing* [online]. 2008, roč. 17, č. 8, s. 1383–1398 [cit. 2020-11-14]. ISSN 1057-7149. Dostupné z DOI: 10.1109/TIP.2008.925382.
25. GUDBJARTSSON, HáKon; PATZ, Samuel. The rician distribution of noisy mri data. *Magnetic Resonance in Medicine* [online]. 1995, roč. 34, č. 6, s. 910–914 [cit. 2020-11-30]. ISSN 07403194. Dostupné z DOI: 10.1002/mrm.1910340618.
26. WANG, Z.; SIMONCELLI, E.P.; BOVIK, A.C. Multiscale structural similarity for image quality assessment. In: *The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, 2003* [online]. IEEE, 2003, s. 1398–1402 [cit. 2020-12-05]. ISBN 0-7803-8104-1. Dostupné z DOI: 10.1109/ACSSC.2003.1292216.
27. *Sørensen–Dice coefficient*. San Francisco (CA): Wikimedia Foundation, 2021. Dostupné také z: https://en.wikipedia.org/wiki/S%C3%B8rensen%E2%80%93Dice_coefficient.
28. GONZALEZ, Rafael C.; WOODS, Richard E. *Digital Image Processing*. 4th ed. London: Pearson Education, 2018. ISBN 978-0-13-335672-4.
29. KUBICEK, Jan; CERNY, Martin; PENHAKER, Marek; AUGUSTYNEK, Martin; MOLNAROVA, Kristyna; KOSTURIKOVA, Jana; BALEJA, Ladislav; OCZKA, David; TIMKOVIC, Juraj. Modeling and Features Extraction of Blood Vessels based on Soft Regional Segmentation. *IFAC-PapersOnLine* [online]. 2018, roč. 51, č. 6, s. 366–371 [cit. 2020-12-06]. ISSN 24058963. Dostupné z DOI: 10.1016/j.ifacol.2018.07.181.
30. MOHAPATRA, Sonisilpa; WEISSHAAR, James C. Modified Pearson correlation coefficient for two-color imaging in spherocylindrical cells. *BMC Bioinformatics* [online]. 2018, roč. 19, č. 1 [cit. 2020-12-05]. ISSN 1471-2105. Dostupné z DOI: 10.1186/s12859-018-2444-3.

Příloha A

Výpisy částí zdrojového kódu

Seznam výpisů zdrojového kódu

A.1 Načtení snímku, kontrola formátu, vytvoření zálohy nativního snímku a následné zobrazení.	101
A.2 Switch aplikace zvoleného šumu a upozornění na kritické stavy.	102
A.3 Funkce exportu dávky zašuměných snímku a parametrů šumu v dávce do workspace.	103
A.4 Funkce uložení dávky zašuměných snímku a parametrů šumu v dávce.	103
A.5 Dávková segmentace pomocí Otsu metody víceúrovňového prahování.	104
A.6 Dávková segmentace pomocí Fuzzy C-means segmentace.	104
A.7 Tvorba seznamu pro výběr regionů k extrakci.	105
A.8 Funkce exportu segmentované dávky a extrahovaných regionů.	105
A.9 Extrakce zvolených regionů cévy a kalcifikace.	106
A.10 Tvorba jména mateřské složky reportu.	106
A.11 Funkce výpočtů jednotlivých evaluačních koeficientů.	107

```
% Získání cesty/souboru
[app.file, path] = uigetfile('*', 'Vyberte snímek');
app.I = imread(horzcat(path, app.file));

% RGB kontrola
[~,~,z] = size(app.I);
if z == 3
    app.I = rgb2gray(app.I);
end

% Vytvoření zálohy snímku
app.IBackup = app.I;

% Zobrazení snímku
app.UIAxes_Noise.Visible = 'on';
figure(app.UIFigure) % Aplikace do popředí
imshow(app.I, 'Parent', app.UIAxes_Noise);
```

Výpis A.1: Načtení snímku, kontrola formátu, vytvoření zálohy nativního snímku a následné zobrazení.

```

% Switch aplikace zvoleného šumu
switch app.TabGroup_2.SelectedTab.Title
    case 'Gauss'
        % Upozornění
        if app.m_max.Value ~= 0 && app.var_gauss_max.Value ~= 0
            warndlg('Pro nastavení obou parametrů Gaussova šumu není podporována
                evaluace.', 'Upozornění');
        end
        if app.m_min.Value ~= 0 || app.var_gauss_min.Value ~= 0
            warndlg('První snímek je referencí. Ponechte "min = 0" pro správnou
                evaluaci!', 'Upozornění');
        end
        [app.J, app.m, app.var_gauss] = fx_GaussNoiseBatch(app.I, ...
            app.OutputcountSpinner.Value, ...
            [app.m_min.Value app.m_max.Value], ...
            [app.var_gauss_min.Value app.var_gauss_max.Value]);
        app.prms = {app.m, app.var_gauss, app.TabGroup_2.SelectedTab.Title};
    case 'Speckle'
        ...
end

```

Výpis A.2: Switch aplikace zvoleného šumu a upozornění na kritické stavy.

```

% Dialogové okno pro pojmenování exportu do workspace
varname = inputdlg({'Variable name [def: I] ', ...
                  'Parameters name [def: prms]'}, 'Input');

% Export dávky zašuměných snímků od workspace
assignin('base', varname{1}, app.J);

% Export parametrů šumu do workspace
switch app.TabGroup_2.SelectedTab.Title
    case 'Gauss'
        assignin('base', varname{2}, {app.m, app.var_gauss, ...
                                       app.TabGroup_2.SelectedTab.Title});

    case 'Speckle'
        ...
end

```

Výpis A.3: Funkce exportu dávky zašuměných snímků a parametrů šumu v dávce do workspace.

```

% Lokální alokace pro uložení - dávka zašuměných snímků
BatchOutput = app.J;

% Získání umístění složky pro uložení
path = uigetdir([], 'Select save file directory');

% Switch uložení dávky snímků a parametrů šumu
switch app.TabGroup_2.SelectedTab.Title
    case 'Gauss'
        params = {app.m, app.var_gauss, app.TabGroup_2.SelectedTab.Title};
        save(strcat(path, '\params_Gaus.mat'), 'params')
        save(strcat(path, '\BatchNoise_Gaus.mat'), 'BatchOutput')
    case 'Speckle'
        ...
end

```

Výpis A.4: Funkce uložení dávky zašuměných snímků a parametrů šumu v dávce.

```

% Prahy
n = N-1;

% Dimenze vstupni cell matice
[x,y] = size(I);

% Otsu multithresh dávková segmentace
for i = 1:x
    for j = 1:y
        thresh{i,j} = multithresh(I{i,j},n);
        L{i,j} = imquantize(I{i,j},thresh{i,j});
        J{i,j} = label2rgb(L{i,j});
    end
end
end

```

Výpis A.5: Dávková segmentace pomocí Otsu metody víceúrovňového prahování.

```

% Dimenze vstupni cell matice
[x,y] = size(I);

% Fuzzy C-means dávková segmentace
for i = 1:x
    for j = 1:y
        [~,~,LUT,~] = FastFCMeans(I{i,j}, N);
        L{i,j} = LUT2label(I{i,j}, LUT);
        J{i,j} = label2rgb(L{i,j});
    end
end
end

```

Výpis A.6: Dávková segmentace pomocí Fuzzy C-means segmentace.

```

% Příprava formátu položek do seznamu
app.val = cell(1,app.RegionCountSpinner.Value);
for i = 1:app.RegionCountSpinner.Value
    app.val{i} = num2str(i);
end

% Vytvoření čísel v seznamu regionů dle zadané hodnoty
app.VesselListBox.Items = app.val;
% Podmínka přítomnosti kalifikace
if app.KalifikaceptomnaCheckBox.Value == 1
    app.KalcifListBox.Items = app.val;
end

```

Výpis A.7: Tvorba seznamu pro výběr regionů k extrakci.

```

% Dialogové okno pro pojmenování exportu do workspace
varname = inputdlg({'Variable name [def: Seg]'},'Input');

% Tvorba 'struct' exportu segmentace a extrakce
Seg.Label = app.Label;
Seg.LV = app.LV;
if app.KalifikaceptomnaCheckBox.Value == 1
    Seg.LK = app.LK;
end

% Export do workspace
assignin('base',varname{1},Seg);

```

Výpis A.8: Funkce exportu segmentované dávky a extrahovaných regionů.

```

% Extrakce zvolených regionů
for h = 1:app.Ldim
    for k1 = 1:app.VLB_num
        app.LabVes{inx,h}(:, :, k1) = app.L{1,h} == app.VLB(k1);
    end
    if app.KalcifikaceptomnaCheckBox.Value == 1
        for k2 = 1:app.KLB_num
            app.LabKal{inx,h}(:, :, k2) = app.L{1,h} == app.KLB(k2);
        end
    end
end

% Extrahované regiony - Label
app.LV{inx,h} = sum(app.LabVes{inx,h},3);

```

Výpis A.9: Extrakce zvolených regionů cévy a kalcifikace.

```

% Tvorba mateřského 'string'u složky reportu
app.MotherDir_str = strcat(app.file, '_', ...
    app.prms{3}, '_', ...
    num2str(app.OutputcountSpinner.Value), '_', ...
    app.ParName, ...
    num2str(app.prms{a}(end)), '_', ...
    num2str(app.RegionCountSpinner.Value), '_(', ...
    cell2mat(app.VesselListBox.Value), '- ', ...
    cell2mat(app.KalcifListBox.Value), ')');

% Generování mateřské složky
app.MotherDir_path = strcat(app.selpath, '\\', app.MotherDir_str);
mkdir(app.MotherDir_path);

```

Výpis A.10: Tvorba jména mateřské složky reportu.

```

% Plocha
app.LV_Area{inx,h} = sum(app.LV{inx,h}, 'all');

% Plocha rozdíl
app.Eval_LV_Area{inx,h} = abs(app.LV_Area{inx,h} - app.LV_Area{inx,1});

% Korelační koef.
app.LV_Corr{inx,h} = corr2(app.LV{inx,1},app.LV{inx,h});

% Sorensen-Dice koef.
app.LV_Dice{inx,h} = dice(app.LV{inx,1},app.LV{inx,h});

% MSE - Mean-squared error
app.LV_MSE{inx,h} = immse(uint8(app.LV{inx,h}),uint8(app.LV{inx,1}));

% SSIM - Structural similarity
app.LV_SSIM{inx,h} = ssim(uint8(app.LV{inx,h}),uint8(app.LV{inx,1}));

% Kalcif. skóre
app.Eval_KS{inx,h} = (app.LK_Area{inx,h}/app.LV_Area{inx,h})*100;

% Kalcif. skóre rozdíl
app.Eval_KS_RefDif{inx,h} = abs(app.Eval_KS{inx,h} - app.Eval_KS{inx,1});

```

Výpis A.11: Funkce výpočtů jednotlivých evaluačních koeficientů.